SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA
Zavod za elektroniku, mikroelektroniku,
računalne i inteligentne sustave

Skripta iz predmeta

Sustavi za rad u stvarnom vremenu

Leonardo Jelenković

Zagreb, 2022.

Predgovor

U računarstvu (koje je pretpostavljeno u nastavku) područje obuhvaćeno imenom “sustavi za rad u stvarnom vremenu” (kratica SRSV) je vrlo opsežno. U ovom se predmetu zato i ne pokušava otići u širinu i pokriti cijelo područje (što je možda i nemoguće), već su odabrane i predstavljene neke teme, kratko predstavljene u ovom predgovoru.

S obzirom na to da se pravi problemi pri analizi, projektiranju, izgradnji i održavanju SRSV-a javljaju u sustavima koji upravljaju s više aktivnosti, tj. u sustavima koji obavljaju više zadaća ili zadataka, glavnina predmeta je posvećena ostvarenju višezadaćnosti u SRSV-ima i rješavanju problema koji se u takvim sustavima pojavljuju. Problemi raspoređivanja zadataka, usklađivanje njihova rada i međusobne komunikacije su glavni problemi. Kako se ti problemi rješavaju prikazano je i korištenjem standardnog POSIX sučelja.

Osim višezadaćnosti, u predmetu se kratko prikazuje problematika analize i programskog ostvarenja upravljačkih zadataka. Pri analizi se mogu koristiti neformalni ili formalni postupci, svaki sa svojim prednostima i nedostacima. Različiti problemi mogu se riješiti prikladnim programskim strukturama. Upravljanje se često ugrađuje u računala manje procesne moći te su jednostavniji algoritmi prikladniji, poput PID upravljanja. Kada se upravljačka funkcija ne može precizno iskazati (zbog nepoznavanja svih ovisnosti i slično), onda se mogu koristiti heuristički pristupi, poput neizrazitog zaključivanja.

Iako je predmet osmišljen na višoj razini apstrakcije i ne ulazi u probleme sklopovlja, ipak su prikazani neki detalji programskih jezika i alata na koje treba pripaziti pri ostvarenju SRSV-a. Operacijski sustavi, koji se mogu koristiti kao podloga SRSV-a, ukratko su opisani, istaknuti su mogući problemi na koje treba obratiti posebnu pažnju. Prikazana su svojstva operacijskih sustava u kontekstu uporabe SRSV-a te preporuke za odabir operacijskog sustava u ovisnosti o zahtjevima.

Sadržaj knjige podijeljen je u poglavlja:

1. Uvod
2. Modeliranje sustava
3. Ostvarenje upravljanja
4. Raspoređivanje poslova
5. Raspoređivanje dretvi
6. Višedretvena sinkronizacija i komunikacija
7. Raspodijeljeni sustavi
8. Posebnosti izgradnje programske potpore
9. Operacijski sustavi

8. 12. 2016. *Leonardo Jelenković*

Sadržaj

1. Uvod

Što su to “sustavi za rad u stvarnom vremenu” u kontekstu računarstva? Iako svi sustavi rade u vremenu, tj. obavljaju aktivnosti koje se protežu kroz neke vremenske intervale, je li protok vremena ključan za obavljanje tih aktivnosti, spadaju li oni u tu grupu? Izvorni engleski termin jest *real time systems* s kraticom RTS ili samo RT. U nastavku se koristi kratica hrvatskog prijevoda *sustavi za rad u stvarnom vremenu* – SRSV.

1.1. Primjeri uporabe računala

Razmotrimo nekoliko primjera gdje se koristi računalo, kakva su očekivanja od tih sustava te koje od njih možemo svrstati u kategoriju SRSV-a.

1.1.1. Uredsko korištenje računala

Uobičajeni uredski posao jest pisanje raznih dokumenata, pisama i slično u primjerenim programima za obradu teksta, tablica, prezentacija i slika. Uobičajene radnje u takvom poslu jesu otvaranje postojećeg dokumenta ili stvaranje novog, pisanje teksta, uređivanje te spremanje, kao na slici 1.1. Napredni će alati imati razne pomoći pri izradi tih dokumenata. Primjerice, ukazivat će na pravopisne greške već tijekom pisanja, prepoznavati posebne unose, primjerice datume, imena i slično te ih ponuditi u uobičajenom formatu i slično.

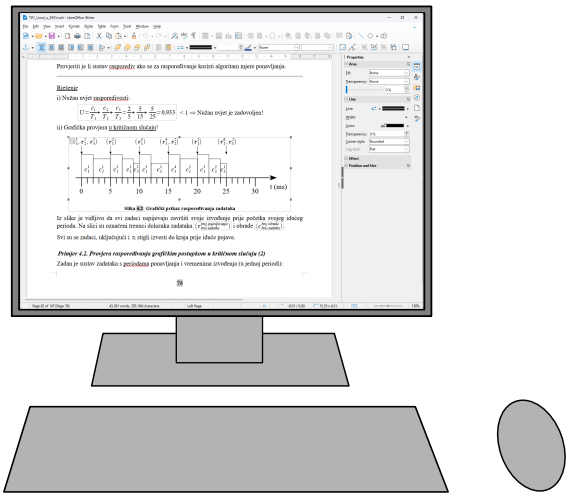

Slika 1.1. Uređivanje dokumenta

Očekivanja korisnika od ovakvih sustava jesu da program omogući što jednostavniji rad, bude pouzdan, tj. da cijelo vrijeme radi bez povremenog smrzavanja ili prekida rada (završava s nekom greškom). Operacije takvih alata nisu vremenski kritične. Dapače, neke od njih mogu potrajati i nešto više, primjerice otvaranje dokumenta i priprema za ispis. Korisnik je navikao da takve operacije mogu potrajati, primjerice nekoliko sekundi ili i više ako je dokument velik, te on to neće smatrati kao loš rad programa. Međutim, jednostavnije operacije moraju biti gotove trenutno. Primjerice, pisanje teksta pretpostavlja da svaki pritisak na neko slovo na tipkovnici bude predstavljen pojavom tog slova u dokumentu gotovo trenutno. “Gotovo trenutno” sa stanovišta čovjeka je subjektivan pojam, ali može se pretpostaviti da ako je kašnjenje prikaza u

odnosu na pritisak tipke manje od npr. 25 ms čovjek to neće primijetiti. Što ako takvo kašnjenje bude i veće? Ako se ono rijetko događa, korisnik to vjerojatno niti neće primijetiti. Ako se kašnjenje događa češće to će kod korisnika izazvati osjećaj sporosti alata, tj. to će biti ubrojeno u nedostatke alata. U takvom će slučaju korisnik možda potražiti i drugi alat (kada ima izbora). Međutim, i u takvom sustavu sa češćim kašnjenjima ili čak i povremenim zaustavljanjima ili i prekidanju rada ipak se ništa kritično neće dogoditi sa sustavom – nitko neće nastradati ili biti počinjena veća materijalna šteta (ako ne ubrojimo izgubljeno vrijeme korisnika).

Sa staništa vremenskih ograničenja, takav rad zbiva se u stvarnom vremenu, ali bez strogih vremenskih ograničenja te bez većih posljedica u slučaju grešaka, uključujući i obične greške programa i sporosti, tj. kašnjenja u reakciji na korisnikove naredbe.

1.1.2. Reprodukcija audio i video sadržaja

Za reprodukciju audio i video sadržaja mogu se koristiti razne naprave, od osobnog računala (i na njemu postavljenog prikladnog programa) do posebnih uređaja, primjerice, prijenosnog MP3 uređaja ili uređaja za prikaz sadržaja na televiziji (engl. *set top box*). Moguće sučelje takva programa/uređaja prikazano je na slici 1.2.

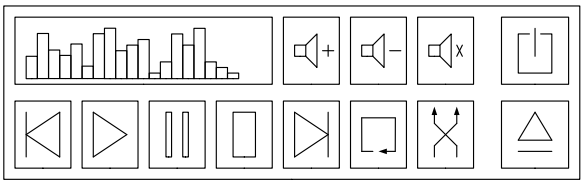

Slika 1.2. Multimedijski uređaj

Kod reprodukcije audio i video sadržaja bitna je vremenska usklađenost reprodukcije i stvarnog protoka vremena. Svaka će se neusklađenost primijetiti u slici ili zvuku. Korisnik će možda podnositi rijetke pojave grešaka (neusklađene reprodukcije), ali češće greške neće jer takve greške značajno utječu na kvalitetu reprodukcije kako ju doživljava korisnik. Stoga reprodukcija mora biti vremenski usklađena, a da bi uređaj (ili program) bio koristan za korisnika.

U slučaju greške ili prestanka ispravne reprodukcije, korisnik će ili ponovno pokrenuti program/napravu ili će odustati od njegovog korištenja. Međutim, kao i u prethodnom primjeru, neće biti većih posljedica.

1.1.3. Računalom upravljani kućanski uređaji

Mnogi kućanski uređaji, kao što su perilica (posuđa, rublja – slika 1.3.) i pećnica (obična, mikrovalna) su upravljane računalom (nekakvim mikroupravljačem).

Navedeni uređaji imaju sučelje preko kojeg korisnik odabere program rada te ih pokreće. Korisnik od uređaja očekuje da prati zadani program, tj. da u određenim vremenskim intervalima sprovodi zadane radnje do okončanja posla. Također, u slučaju nepredviđenih poteškoća, korisnik očekuje prikladno ponašanje uređaja. Primjerice, ako dođe do prekida električnog napajanja te ponovne uspostave, korisnik minimalno očekuje da uređaj ne započne neki drugi posao te da ima mogućnosti ponavljanja zadanog posla ili barem jednostavnog načina prekida. U primjeru perilice to bi pretpostavljalo da ima program koji će primjerice moći sam izbaciti vodu iz perilice prije njezina otvaranja. Drugi neočekivani događaji mogu biti prekid u dotoku vode, previsoka temperatura vode/zraka i slično. Od uređaja se očekuje da mogu primijetiti takve situacije i prikladno reagirati (npr. zaustaviti daljnji rad). Ako uređaj nema prikladne

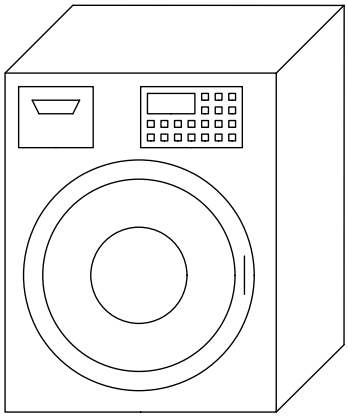

Slika 1.3. Perilica rublja

senzore za takve moguće situacije, mogu se dogoditi značajne nezgode. Primjerice, uređaj se može zapaliti i zazvati požar u kućanstvu, kuhinja/kupaonica može biti poplavljena i slično. Te nezgode mogu imati značajne materijalne i ljudske posljedice. Stoga takve uređaje treba pomnije osmisliti, projektirati i ispitati.

Iako ovakvi uređaji ne trebaju jaču procesorsku snagu jer operacije kojima upravljaju su poprilično spore, primjerice sekunda kašnjenja ne predstavlja nikakav propust, vremenska usklađenost na većoj skali je ipak potrebna. Npr. na primjeru perilice rublja, u slučaju nasilna otvaranja vrata uređaja, program bi to trebao detektirati i odmah zaustaviti vrtnju i dotok vode.

1.1.4. Lift u zgradi

Lift prevozi ljude i njihove stvari s jednog kata na drugi. Ilustracija lifta na katu prikazana je na slici 1.4. Akcije koje upravljačko računalo lifta pokreće uključuju pravovremeno otvaranje i zatvaranje vrata lifta dok on stoji na katu, pomicanje lifta prema gore ili dolje, zaustavljanje lifta na potrebnim katovima, upravljanje tipkama u liftu i na katovima, uključivanje potrebne signalizacije (na kojem je katu, kamo ide, gdje će stati, . . .).

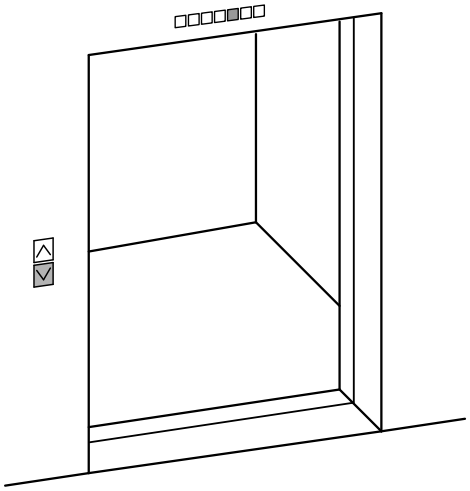

Slika 1.4. Lift

Upravljanje liftom jest kritičan posao jer neke greške upravljanja mogu izravno utjecati na ljude koji ga koriste. Iako su akcije koje upravljačko računalo lifta pokreće u granulaciji sekunde ili

i više, te akcije raznih elemenata moraju biti usklađene. Primjerice, vrata se ne smiju otvarati prije nego li lift stane, lift ne smije krenuti prije nego li su vrata zatvorena.

1.1.5. Automatizirano skladište

Razmotrimo jedno hipotetsko skladište prema slici 1.5. koje je potpuno pod upravljanjem računalnog sustava koji koordinira autonomnim vozilima (npr. viljuškari) koja premještaju proizvode po skladištu, ukrcavaju i iskrcavaju proizvode na kamione koji dolaze pred skladište (lijevo na slici).

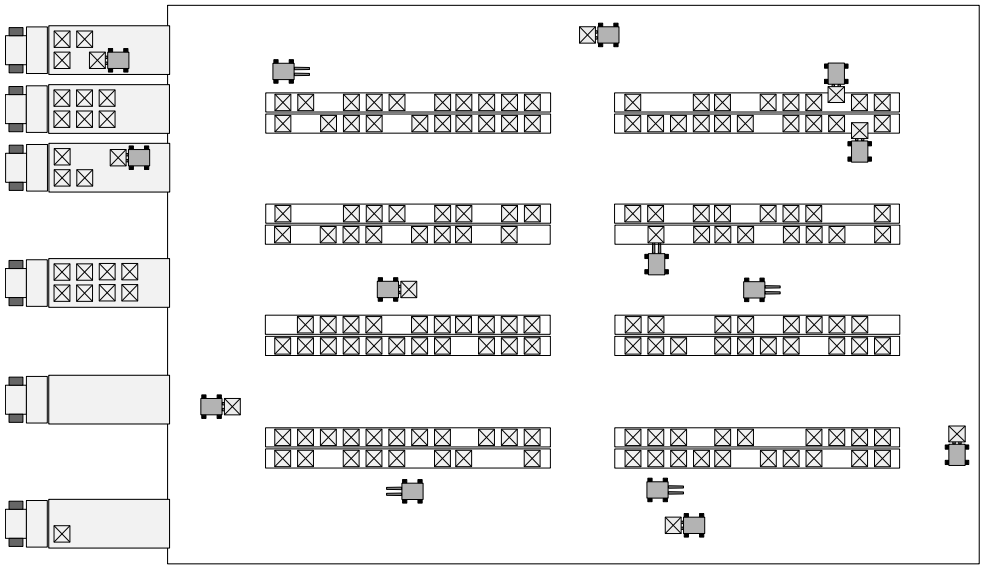

Slika 1.5. Automatizirano skladište

Upravljanje takvim složenim sustavom zahtjeva usklađenu koordinaciju svih vozila, njihovih puteva po skladištu, stavljanju i uzimanju proizvoda s odgovarajuće police ili kamiona na vozilo i s vozila na policu ili u kamion, sve složeno po nekim načelima, primjerice optimirano radi brzine ukrcaja i iskrcaja s kamiona. Greške u upravljanju mogu dovesti do sudara vozila s preprekom (zidom, kamionom, policom ili drugim vozilom), oštećenja proizvoda i slično. Ako u takvom sustavu ne sudjeluju ljudi (izravno u skladištu), greške upravljanja neće imati i ljudske posljedice. Ipak, materijalne posljedice mogu biti značajne. Osim oštećenja proizvoda, vozila, kamiona i inventara, šteta može biti i zbog neoptimalnog rada što dovodi do odgode, zbog koje mogu biti oštećeni svi dionici u lancu. Primjerice, ako je jedan kamion napunjen sat vremena prekasno možda neće svoj teret stići istovariti na brod ili će brod zbog njega morati biti zadržan duže u luci.

Kao i u prethodna dva primjera (kućanski uređaji, lift) i ovaj primjer uporabe računala spada u skupinu kritičnih poslova i sa stanovišta vremena i s posljedicama koje donose greške upravljanja.

1.1.6. Usporedba sustava

U primjerima pisanja dokumenta i reprodukcije multimedije (i sličnim) mogućnost rijetkog narušavanja ispravnog rada se i ne promatra kao nešto značajno loše za rad sustava. Međutim, u ostalim navedenim primjerima kao i mnogim drugim sustavima to nije tako. Npr. pri upravljanju letjelicom, projektilom, autom, industrijskim procesom, upravljačko računalo mora *uvijek*

ispravno raditi, bez zastoja, bez obzira na sve ostale poslove i događaje u sustavu, bez obzira na ostale ulaze i stanje sustava. Za neke je sustave dovoljno da se samo u jednom trenutku dogodi greška, npr. da sustav ne daje ispravne naredbe na vrijeme, a da se dogodi problem (ispad sustava, kvar, sudar, neispravni proizvodi, ozljede korisnika sustava). Takvi sustavi moraju biti upravljani programskom potporom za koju kažemo da "radi u stvarnom vremenu" – u pravom trenutku daje prave podatke, naredbe, prema svojoj okolini.

Mnogi sustavi nisu građeni da zadovoljavaju vremensko usklađeno upravljanje te se kod njih niti ne mogu postići takva upravljanja. Primjerice, u osobnom računalu bi mogli povećati prioritet programu koji radi reprodukciju video sadržaja s namjerom da se uvijek izvodi prije svih ostalih programa. Međutim, to nije uvijek dovoljno. Mnoge se operacije obavljaju u okviru operacijskog sustava, kao što je upravljanje ulazno izlaznim napravama, te bi i samo te operacije u nekom kritičnom trenutku mogle zauzeti previše procesorskog vremena, a da ostane dovoljno za pravilnu reprodukciju videa (npr. intenzivna komunikacija preko mreže koja pritom zahtjeva i dohvat/pohranu podataka na disk).

Da bi se mogla ostvariti željena svojstva sustava za rad u stvarnom vremenu svi elementi sustava trebaju biti prikladni za to, od sklopovlja, operacijskog sustava do programa i samih korisnika sustava.

Složeni upravljački sustavi, kakvi se danas često susreću, najčešće sadrže elemente koji jesu kritični te elemenate koji to nisu. Upravljanje jednim i drugim elementima, kritičnim i nekritičnim, izvodi se zasebnim, odvojenim komponentama (mikroračunalima), obzirom da se ne želi da nekritične komponente kompromitiraju kritične. Iako postoje mehanizmi koji bi trebali osigurati kritičnim programima prednost (npr. raspoređivanje prema prioritetu), zbog složenosti sustava ipak postoje mogućnosti da nekritični programi osjetno utječu na kritične. O tome više u poglavlju 10. o operacijskim sustavima.

1.2. Osnovni pojmovi u kontekstu SRSV-a

Gotovo svi sustavi koji nas okružuju mijenjaju se s protokom vremena. Za neke smo promjene mi odgovorni ili barem sudjelujemo u njima, dok su druge izvan našeg interesa ili moći. Promjene kojima smo mi uzroci događaju se zbog naše izravne upletenosti u njih ili zbog strojeva koje smo postavili da u njima sudjeluju. U nastavku se razmatraju samo oni sustavi koji su upravljani računalom u obliku programa koji obavlja programirane operacije ili uz upravljanje čovjeka (čovjek upravlja sustavom posredstvom računala). Opća slika takvog sustava prikazana je na slici 1.6.

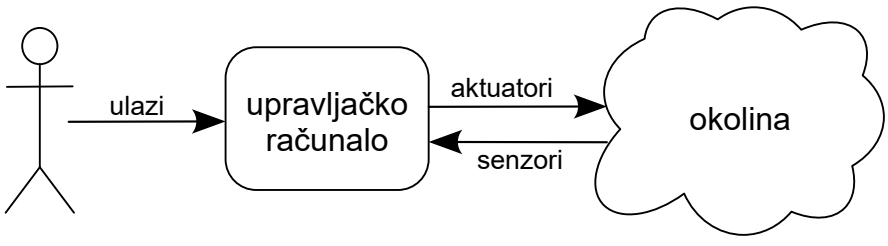

Slika 1.6. Sustavi upravljani računalom

Računala se ugrađuju u našu okolinu radi njihove mogućnosti preciznijeg i bržeg računanja i reakcije na događaje, kao i radi oslobađanja čovjeka od obavljanja zamornih operacija. Neke od tih primjena su u nekritičnim sustavima dok su druge primjene u kritičnim sustavima. Projektiranje sklopovske i programske komponente za jedan i drugi sustav stoga neće biti isto.

Kod projektiranja kritičnih sustava koristit će se značajno stroži kriteriji kako u odabiru sklopovskih komponenti tako i u pristupu izradi programskih. Poželjno bi bilo i nekritične sustave projektirati na taj način, ali često bi to dovelo do značajnog povećanja cijene te se pri njihovu projektiranju radi kompromis između kvalitete i brzine izrade. Npr. ne koriste se uobičajeni procesi razvoja već se koriste ubrzani procesi koji će prije dati rezultat nauštrb preglednosti, arhitekture, optimalnosti, ispitivanja, ne koriste se skupi (izvrsni) programeri već jeftiniji.

1.2.1. Ispravnost, greške, zatajenje

Ako sustav obavlja ono što se od njega traži, uz prihvatljivu kvalitetu produkata, sustav je *ispravan*. Kako kvaliteta proizvoda pada tako je i *korisnost* sustava manja.

Zbog raznih okolnosti sustav može doći u *neočekivana stanja* u kojima ne obavlja predviđenu operaciju. Ako su ta stanja kratkotrajna te se sustav iz njih može izvući (pod upravljanjem računala) onda se radi samo o kratkotrajnoj *grešci* sustava. U protivnom, ako se sustav nakon greške ne može oporaviti radi se o *zatajenju* sustava. Posljedice grešaka i zatajenja mogu biti samo materijalne ili imati posljedice i za ljude u okolini upravljanog sustava.

Uzroci zatajenja mogu biti izvan upravljanog sustava (“ptica je kroz prozor uletjela u stroj i začepila dovod zraka”) ili iznutra. Ako je greška nastala unutar sustava, uzrok može biti sklopovski (“pukla osovina”) ili greška upravljačkog računala (programa). U idućim razmatranjima promatraju se samo svojstva upravljačkog računala, tj. njegove programske potpore.

Kada program ne radi *ispravno*, kako se greška pokazuje?

1.2.2. Logička ispravnost

Kod projektiranja programske komponente računalnih sustava pred projektante se postavljaju razni zahtjevi. Program treba na osnovu ulaza izračunati valjane (očekivane) izlaze prema postupcima koji su zadani uz problem. Navedeni zahtjev nazivamo *logičkom ispravnošću*. Kod mnogih primjena logička ispravnost je dovoljna, primjerice za:

- program za proračun plaća
- inženjerske proračune (npr. naprezanja, struje/naponi, . . .)
- izradu audio/video sadržaja (ali ne i njihovu reprodukciju)
- obradu teksta.

Svi programi bi trebali davati logički ispravne rezultate. Međutim, kod nekih sustava samo logička ispravnost nije dovoljna.

1.2.3. Vremenska ispravnost

Ispravan rezultat ili naredba vanjskoj napravi često nije dovoljna, a da sustav ispravno radi. Dodatno je potrebno da taj rezultat bude pripremljen u pravom trenutku. Vremenska neusklađenost izračuna podatka može dovesti do smanjenja kvalitete, grešaka ili čak do zatajenja.

U primjerima 1.1.1.-1.1.5. već je analizirana potreba vremensko uskađenog upravljanja. Osim što upravljački program/računalo mora generirati potrebne naredbe to mora raditi u pravim trenucima. Ako se naredba daje prerano ili prekasno sustav može snositi posljedice. Možemo reći da osim logičke ispravnosti od ovih se sustava zahtjeva i *vremenska ispravnost*.

1.2.4. Sustavi za rad u stvarnom vremenu

Sustavi za rad u stvarnom vremenu su sustavi kod kojih je osim *logičke ispravnosti* još bitnija *vremenska ispravnost*.

Iako primjere 1.1.1.–1.1.5. možemo sve svrstati u SRSV-e, očito je da će pojedino narušavanje vremenske ispravnosti ipak imati znatno različite posljedice. Zato se često u kontekst SRSV-a ubrajaju samo sustavi koji upravljaju stvarnim procesima u našoj okolini, gdje su posljedice grešaka značajne (materijalne ili posljedice po čovjeka). U ovom tekstu se sustavi neće razlikovati, mada je jasno da pri projektiranju takvih sustava treba biti znatno oprezniji nego pri projektiranju igara ili multimedijalnih programa.

1.2.5. Podjela SRSV-a

Postoje mnoge podjele SRSV-a s obzirom na različite aspekte. Jedna od njih je podjela s obzirom na osnovu izvora poticaja za akciju u sustavu. Tako razlikujemo sustave *pobuđivane događajima* (engl. *event triggered systems*) te *sustave upravljane protokom vremena* ili *ritmom okidane sustave* (engl. *time triggered systems*).

Ipak, osnovna podjela SRSV-a zasniva se na očekivanjima od sustava, tj. posljedicama nepoštivanja definiranih ograničenja. SRSV-i se prema tom kriteriju dijele na:

- *stroge* (engl. *hard RTS*),
- *ublažene* (engl. *soft RTS*) te
- *čvrste* (engl. *firm RTS*).

Kod strogih SRSV-a zadana vremenska ograničenja treba strogo poštovati. Ako se i makar jednom to ne postigne sustav zakazuje. Primjerice, neka u nekoj tvornici montažu nekog uređaja rade robotske ruke na traci. U slučaju da i jedna ruka zakaže i na jednom proizvodu ne napravi ono što treba, može se dogoditi da cijela traka stane, jer iduća robotska ruka ne može nastaviti s radom (može se čak i pokvariti pokušavajući obaviti svoj posao).

Ublaženi SRSV-i neće u potpunosti zakazati ako se poneko vremensko ograničenje ne ispoštuje. Primjerice, neka u nekoj proizvodnji računalo upravlja grijanjem gdje je točno zadano koliko grijanje treba biti upaljeno (npr. treba proračunati prema masi objekata). Ako računalo drži grijanje upaljeno malo dulje ili kraće trenutni objekt neće biti optimalne kvalitete. Ako se to događa sporadično, objekti lošije kvalitete izbacit će se iz sustava u procesu kontrole i ukupna šteta bit će jednaka samo gubitku zbog tih sporadičnih loše grijanih objekata. Međutim, sustav će i dalje moći raditi. Naravno, ako je broj takvih defektnih proizvoda velik, a iz razloga lošeg upravljanja računala, onda sustav upravljanja nije zadovoljavajući.

Uobičajeno se svojstva sustava u ovom kontekstu procjenjuju prema vremenu reakcije na vanjski događaj. Slika 1.7. prikazuje upravljačko računalo koje prima informacije iz okoline preko senzora te na taj način detektira neki događaj.

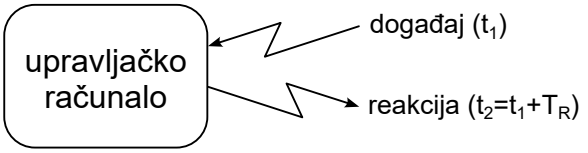

Slika 1.7. Vrijeme reakcije na vanjski događaj

Za stroge sustave, vrijeme reakcije mora biti kraće od unaprijed poznate maksimalne vrijednosti

(T_{Rmax}), inače dolazi do zatajenja, odnosno korisnost sustava (K) pada na nulu. Za ublažene sustave dozvoljeno je prekoračivanje, ali to smanjuje korisnost sustava. Slika 1.8. grafički prikazuje (uspoređuje) stroge i ublažene SRSV-e prema vremenima reakcije na događaje.

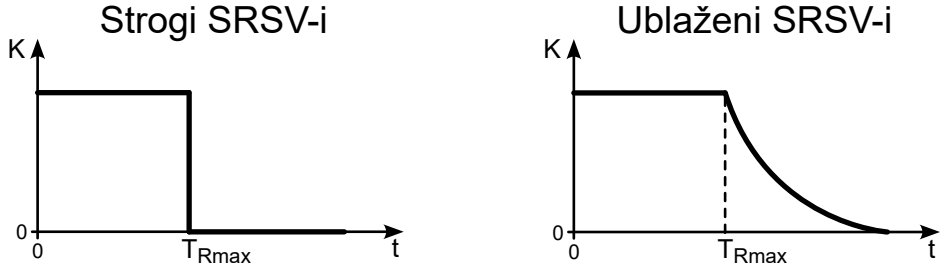

Slika 1.8. Usporedba strogih i ublaženih SRSV-a prema vremenu reakcije

U novijoj literaturi se spominje i treća grupa – čvrsti SRSV-i, kao sustavi koji dozvoljavaju poneko kašnjenje ili čak izostanak reakcije bez posljedica, ali samo ukoliko su to rijetke pojave. Kašnjenje ili izostanak rekacije na nekoliko uzastopnih događaja će ipak biti kobno za sustav. Primjerice, sustav navigacije može ponekad krivo očitati ili interpretirati ulaze senzora i ne otkriti prepreku. Međutim, ako se uzorkovanje obavlja dovoljno velikom frekvencijom, već će iduća ispravna očitanja i interpretacije spriječiti sudar. U protivnom, ako nekoliko uzastopnih očitanja i interpretacije budu krive može se dogoditi sudar.

1.2.6. Vrste događaja

Jedno od osnovnih obilježja SRSV-a (njegove upravljačke komponente) je njegova pravovremena reakcija na događaje. Događaje može izazivati upravljačko računalo ili im izvor može biti iz okoline (dojavljeni preko senzora).

Događaji mogu biti *periodički*, *aperiodički* ili *sporadični*, odnosno *sinkroni* ili *asinkroni*.

Periodički događaji se uvijek javljaju s istim vremenskim razmakom – periodom. Najčešće su inicirani unutar upravljačkog računala, preko njegova sata. Npr. svakih 50 ms treba očitati senzor i prikladno reagirati. Drugi izvor su vanjski periodični događaji – senzor izaziva prekid na koji se pokreće obrada. Iako su i ovi drugi u biti periodični, upravljački programi se znatno razlikuju, tj. upravljački program za ove druge je sličniji upravljanju sporadičnih i aperiodičnih. Osim periode, za periodične događaje se propisuje i vrijeme odgovora – kada događaj mora biti obrađen u upravljačkom računalu, izraženo relativno, od početka periode (uobičajena oznaka je d od engleskog *deadline*). Ukoliko interval nije zadan, implicitno se postavlja na kraj periode (d=T). Za primjer periodičkih događaja razmotrimo neko industrijsko postrojenje koji koristi traku na kojoj se pomiču objekti u raznim fazama obrade koje obavljaju zasebni roboti. Pomicanje trake može biti upravljano računalom koje periodički pomiče traku, npr. svakih 5 minuta. Pojedini roboti preko senzora detektiraju kad se ispred njih pojavi novi objekt, što će u ovom slučaju opet biti periodički događaj.

Događaje koji se ne javljaju periodički, već u nepredvidljivim trenucima, izazivaju događaji iz okoline te se detektiraju u upravljačkom računalu preko očitanja senzora. U kontekstu SRSV-a uobičajena podjela takvih događaja jest na aperiodične i sporadične.

Aperiodički događaji, kao što im i ime kaže nisu periodični već se javljaju rijetko, u nepredvidljivim trenucima. Mogu imati zadano maksimalno vrijeme reakcije, ali i ne moraju. Primjeri aperiodičnih događaja jesu prekidi vanjskih jedinica, događaji koje generira korisnik sustava (mišem, tipkovnicom), sporadični mrežni paketi i sl. U prethodnom primjeru s proizvodnjom

na traci, aperiodični događaj bi mogao biti trenutak primitka informacije o grešci u objektu koje prima glavno upravljačko računalo (koje i pomiče traku) a koju šalje neki robot koji je grešku detektirao. To bi moglo uzrokovati da svi roboti dalje na traci preskoče taj objekt u obradi – nad njim ne rade ništa (jer tu naredbu dobiju od glavnog računala). Kada bi se događaj ignorirao, ukupna "šteta" je u potrošenom vremenu obrade svih robota nad tim objektom, obzirom da će se on ionako baciti.

Sporadični događaji, su po pojavi slični aperiodičkima, ali koji se ipak češće javljaju te za koje je poznato minimalno vrijeme između dva takva događaja. Za njih je, kao i za periodične, zadano maksimalno vrijeme reakcije koje treba poštivati. Primjeri sporadičnih događaja su reakcije na neka očitanja senzora (očitanja mogu biti i periodička), zapisivanje u dnevnik sustava i slično. Razmotrimo isti prethodni primjer s trakom. Neka se traka pomiče tek kada su svi roboti završili svoje operacije nad svojim trenutnim objektom. Nadalje, pretpostavimo da vremena obrade objekata od strane robota mogu biti različita - svakom robotu može trebati različito dugo da napravi svoj posao, a to vrijeme može ovisiti i o objektu nad kojim se radi. S obzirom na ta različita trajanja pomicanje trake će biti nepravilno, u sporadičnim trenucima.

Ako se neki događaji obavljaju istovremeno s nekim drugim događajima u računalnom sustavu, onda kažemo da su te dvije skupine događaja *sinkronizirane*. U protivnom događaji su nepovezani ili *asinkroni*. Npr. signal koji se javlja svakih 10 ms je sinkroni, signal koji se uvijek javlja u unaprijed poznatim trenucima (ne nužno periodičkim) je također sinkroni (može se uskladiti pokretanje odgovarajućih operacija koje će biti sinkrone tim događajima). Za prethodni primjer s pokretnom trakom možemo reći da su počeci rada robota na traci sinkroni sa završetkom pomicanja trake (oni počnu raditi kad novi objekt dođe pred njih). S druge strane, završeci rada pojedinih robota su međusobno asinkroni događaji.

1.2.7. Operacijski sustav

Operacijski sustav (kratica OS) se ukratko može definirati kao "skup programa koji olakšava korištenje računala". OS kao dodatni sloj u računalnom sustavu pojednostavljuje korištenje sklopovlja jer "maskira" specifičnosti sklopovlja (odgovarajućim upravljačkim programima, engl. *device drivers*) te omogućuje njegovo korištenje kroz jednostavno sučelje prema programima (engl. *application programming interface – API*) i prema korisniku (engl. *graphical user interface – GUI*). OS također nudi ostale usluge potrebne za višezadaćni rad (izolacija procesa, sinkronizacija i komunikacija među dretvama, raspoređivanje dretvi). Uloga OS-a u računalnom sustavu ilustrirana je na slici 1.9.

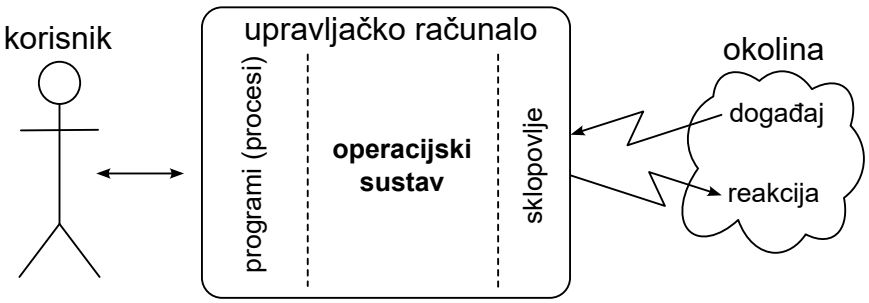

Slika 1.9. Uloga operacijskog sustava u računalnom sustavu

Iz razloga proširivosti, jednostavnosti, prenosivosti i slično, mnogi računalni sustavi (gotovo svi netrivijalni) koriste operacijski sustav. Međutim, obzirom da je OS dodatni sloj između programa i sklopovlja, ako nije prikladno napravljen može izazvati dodatne probleme u ostvarenju vremenske ispravnosti.

Operacijski sustavi su izgrađeni za određene namjene. Primjerice, operacijski sustav za osobno računalo je građen s namjerom korištenja računala kao uredskog računala (podrška uredskim programima), kao multimedijalni stroj, kao stroj za igranje i slično. S obzirom na to da nije građen kao stroj za upravljanje kritičnim sustavima on niti nema potrebna svojstva za SRSV, a jedno od najvažnijih jest brza reakcija na događaje uvijek, ne u "samo" 99.9% slučajeva. Potrebna brzina reakcije zapravo ovisi o sustavu kojim se upravlja i može se kretati od nekoliko mikrosekundi do nekoliko sekundi ili i dulje. Vrijeme reakcije od nekoliko milisekundi općenito se smatra kao zadovoljavajuće za prosječne SRSV-e.

1.2.8. Sklopovlje za SRSV

SRSV-i se mogu ostvariti na raznom sklopovlju. Ipak, sklopovlje koje je projektirano s namjenom korištenja u SRSV-ima ima znatno bolja svojstva u tom okruženju. S druge strane, sklopovlje koje je projektirano za sustave s mnoštvo predviđenih operacija, kao što su to osobna računala, prijenosnici, ručna računala, mobiteli, poslužitelji i slično, najčešće nema mehanizme koji osiguravaju vremensku ispravnost. Npr. iako procesor osobnog računala može biti i za red veličine brže od onog koji se koristi za upravljanje nekog kritičnog procesa, vrlo je vjerojatno da se osobno računalo ne bi moglo tamo ugraditi. Nisu problem samo dimenzije. Osobno računalo sastoji se od mnoštva komponenata – s tim je ciljem i projektirano – da bude proširivo. Upravljanje tim komponentama će ponekad oduzeti nepredviđeno vrijeme. Npr. jedan sklop može zbog svojeg sporog rada spriječiti procesor u korištenju sabirnice, a time i posluživanje i upravljanje s drugim komponentama. Ta odgoda u SRSV-ima može prouzročiti zatajenje sustava. U nastavku se ne razmatra sklopovlje, pretpostavlja se da je ono zadovoljavajuće s aspekta SRSV-a te je sav fokus prebačen na programsku potporu i kako ju ostvariti.

1.2.9. Determinističko ponašanje

Upravljanje sustavom podrazumijeva da se na osnovi trenutnog stanja sustava i poznavanja povijesti zbivanja u sustavu, može donijeti upravljačka odluka za promjenu u željeno buduće stanje. Odluka se potom pretvara u upravljačke signale koji će putem prikladnih uređaja usmjeriti sustav u skladu s odlukama (donesenim, tj. izračunatim u upravljačkom računalu). Da bi navedeno bilo moguće sustav mora biti *predvidiv*, tj. mora unaprijed biti poznato kako će određena akcija koja se pokreće utjecati na cjelokupni sustav, i to *za svako moguće stanje sustava*. Drugim riječima, ako se sustav nalazi u stanju $\underline{X}$ (koji opisuje to stanje), onda će on s akcijom $\underline{a}$ uvijek otići u stanje $\underline{Y}$. Za takav sustav kažemo da ima *determinističko ponašanje* (predvidljivo). Sustav koji nije deterministički je *stohastički* (nepredvidljiv).

SRSV-i moraju biti deterministički jer se u protivnom ne bi mogli upravljati. To se odnosi i na sklopovlje i na operacijski sustav i na programe.

Primjerice, ako se ne može odrediti najdulje vrijeme reakcije (u najgorem slučaju) na točno određeni događaj bez obzira na trenutno stanje sustava, sustav nije deterministički i nije upotrebljiv za SRSV. Zato stolno računalo ni sklopovljem ni operacijskim sustavima nije uporabljivo za SRSV-e.

Da bi računalni sustav bio prikladan za određenu SRSV primjenu, on mora imati odgovarajuće sklopovlje, odgovarajući operacijski sustav te odgovarajuće programe, sve pripremljeno da zadovoljava zadana logička i vremenska ograničenja.

1.2.10. Pouzdanost

Sustavi koji svoj posao uvijek obavljaju u skladu s očekivanjima su *pouzdani sustavi*. Postizanje pouzdanosti sustava (engl. *reliability*) znači obuhvatiti sve zahtjeve postavljene pred sustav i njihovo ispravno obavljanje u ostvarenom sustavu. Osim izgradnje pouzdanog sustava, zadatak je inženjera da to pouzdanje prenesu korisniku, da i on vjeruje u ispravan rad sustava, da se pouzda u njegovo upravljanje svojom okolinom. Ostvarivanje povjerenja korisnika nadilazi ova razmatranja, ali opća načela kao što su uvid u metodologije korištene pri ostvarenju sustava, prikaz dokumentacije, prikaz obavljenih ispitivanja će tome sigurno pridonijeti.

1.2.11. Robusnost

Ispravan sustav je ono što kupac očekuje od proizvođača. Međutim, treba predvidjeti da će se tijekom rada pojavljivati određene izvanredne situacije. Npr. zbog dotrajalosti će se neka komponenta pokvariti (npr. neki aktuator). Preporučljivo bi bilo za sve takve komponente za koje se očekuju kvarovi (npr. iz iskustva radnika), da ih se posebno prati s dodatnim senzorima. U slučaju detekcije kvara mogu se trenutno poduzeti odgovarajuće akcije (zaustaviti proizvodnju da se ne dogodi veća šteta).

Nije realno očekivati da će programska komponenta sustava biti bez greške u svim situacijama. Bilo bi dobro za neke osnovne dijelove upravljačkog programa ugraditi dodatne provjere i dodatno provjeriti da njihovi izlazi budu u dozvoljenim granicama. Npr. određene kritične proračune obavljati na dva načina, pomoću dviju (ili više) metoda. Ako se rezultati poklapaju ili je razlika zanemariva onda koristiti te rezultate. U protivnom zaustaviti sustav i alarmirati osoblje da razriješi problem.

Po potrebi koristiti i druge postupke koji će se primijeniti u slučaju detekcije greške u programu. U SRSV-ima se ne smije dogoditi da program zbog greške jednostavno stane (ili ga operacijski sustav prekine).

Za vrlo kritične sustave može se primijeniti i princip redundantnog upravljanja. Primjerice, umjesto jednog upravljačkog računala mogu se koristiti dva ili više koji rade istu obradu, dobivaju iste ulaze ili svaki od svojih senzora. Ako jedno računalo ispadne zbog sklopovske ili programske greške drugo može odmah prihvatiti upravljanje.

Sustavi koji nisu pod stalnim nadzorom čovjeka, odnosno sustavi kojima je teško pristupiti mogu imati ugrađen još jedan oblik oporavka od pogreške. Posebnim sklopovljem može se nadzirati ispravnost rada. Kad se primijeti da sustav ne reagira na zahtjeve tog sklopovlja, sustav treba zaustaviti i ponovno pokrenuti (*resetirati*). Navedeni mehanizam naziva se *nadzorni alarm* (engl. *watchdog timer*).

Sustavi koji su napravljeni da mogu nastaviti s radom i nakon raznih (neplaniranih) nepovoljnih događaja mogu se smatrati *robusnim* (engl. *resilient*). SRSV-i koji su u duljim vremenskim razdobljima bez nadzora trebali bi biti građeni i prema kriteriju robusnosti.

1.3. Načini upravljanja

Procesi kojima računalni sustav upravlja mogu biti *kontinuirani* i/ili *diskretni*.

Kontinuirani sustavi se kontinuirano mijenjaju i trebaju kontinuirano upravljanje. Primjerice, upravljanje slavinama u nekom kemijskom postrojenju treba stalan nadzor i podešavanja protočnosti kroz pojedine cijevi, a da bi se u određenim elementima sustava odvijale željene reakcije s potrebnim omjerima različitih smjesa u različitim trenucima vremena.

Diskretni sustavi mijenjaju stanje u diskretnim trenucima. Primjerice, upravljanje skretnica nekog željezničkog kolodvora obavlja se ili na intervenciju operatera ili na senzore koji otkrivaju dolazak vlakova ili u točno određenim trenucima usklađenim s redom vožnje.

Većina sustava ima dijelove koje treba kontinuirano upravljati i dijelove koji traže pozornost u diskretnim trenucima. Računalo, kao upravljačka komponenta je u osnovi diskretno, obavlja instrukciju za instrukcijom, jednu za drugom, jednu operaciju za drugom, jedan zadatak za drugim. Ipak, s obzirom na to da računalo to obavlja vrlo velikom brzinom u usporedbi sa čovjekom, ono može prilagoditi frekvenciju kojom zadaje naredbe te tako zadovoljiti i kontinuirane sustave s većom frekvencijom naredbi i očitanja senzora i diskretne sustave čije senzore dovoljno često provjerava ili koji su spojeni tako da izazivaju prekid.

Okruženja koja razmatramo i čije procese želimo upravljati i nadzirati sastoje se od:

- sustava kojim se upravlja ili koji se nadzire (npr. automobil, robot, stroj)
- upravljač (npr. čovjek, računalo)
- okoline u kojoj se sustav nalazi i koju sustav koristi i mijenja.

Upravljanje se odvija upravljanjem elementima sustava, tzv. *aktuatorima*. Ako je sustav upravljan računalom, onda se upravljački signali koje ono šalje u aktuatorima pretvaraju u sile kojim oni djeluju na sustav (i okolinu). Slika 1.10. prikazuje poopćeni *upravljački sustav*.

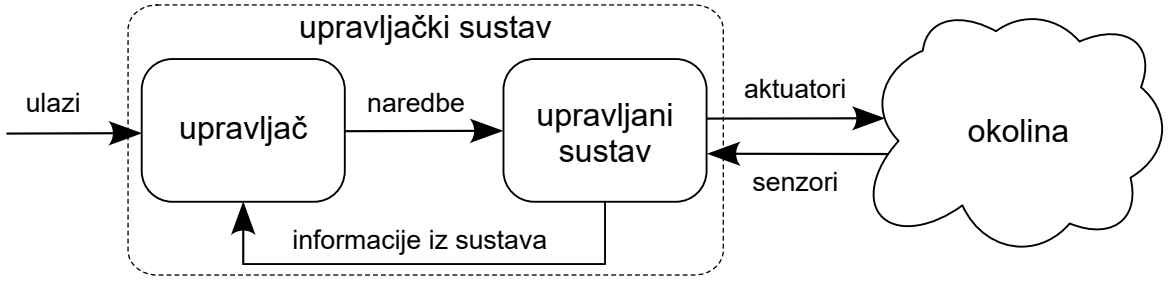

Slika 1.10. Opći upravljački sustav

Interakcija sustava s okolinom je dvosmjerna: sustav mijenja okolinu, ali i preko senzora očitava stanje okoline. Upravljač prima povratne informacije od sustava, ali i naredbe od operatera (korisnika). U nastavku se pretpostavlja da je upravljanje ostvareno računalom koje je ugrađeno u sam sustav te se upravljač i sustav prikazuju jednom komponentom – *upravljački sustav*.

S obzirom na odnos upravljačkog sustava i okoline razlikujemo:

- sustave za nadzor
- upravljanje bez povratne veze (engl. *open-loop control*)
- upravljanje s povratnom vezom (engl. *closed-loop control, feedback control*).

1.3.1. Sustavi za nadzor

Sustavi za nadzor prikupljaju podatke iz okoline, obrađuju ih te na prikladan način prikazuju operaterima. Primjeri nadzornih sustava su alarmni sustavi, video nadzor (uz računalnu obradu), radarski sustavi, mjerači onečišćenja i slični. Prikupljanje podataka može biti inicirano iz okoline ili iz nadzornog sustava. Npr. pritisak na senzor stvara signal koji se registrira u nadzornom sustavu (koji tada može pokrenuti alarm na operaterovu zaslonu). Prikupljanje podataka inicirano iz nadzornog sustava je najčešće periodičko, svaki se senzor periodički očitava, obrađuje, eventualno prikazuje i pohranjuje.

1.3.2. Upravljanje bez povratne veze

Upravljanje bez povratne veze, odnosno upravljački sustav koji ne očitava rezultate svojih upravljačkih odluka, donosi odluke na osnovi zahtjeva operatera ili na temelju unaprijed programiranih operacija, bez da prati (za vrijeme upravljanja) kako se njegove odluke sprovode i odražavaju na okolinu. Npr. neki se alatni stroj može programirati da predmet obrađuje na točno određeni način, zadanim brzinama pomičući i alat i predmet obrade. Oblik ulaza te željeni oblik gotova objekta mogu biti ulazi, a program će izračunati sve potrebne radnje, brzinu gibanja komponenata i slično.

Problem ovakvog upravljanja jest što ih se ne smije ostaviti bez nadzora. Npr. ako pri radu alatnog stroja nešto krene krivo, npr. svrdlo pukne, a ne koristi se povratna veza, osim što se proizvod neće oblikovati prema zadanom obliku, stroj se može i dodatno oštetiti. Ipak, za mnoge je sustave ovaj način upravljanja zadovoljavajući, pogotovo stoga što se značajno jednostavnije ostvaruje od upravljanja koje koristi povratnu vezu. Ovakvi se sustavi mogu nadograditi zasebnim senzorima koji će zaustaviti sustav ako se nešto nepredviđeno dogodi (dodatak nije dio upravljanja). Ako računalom izravno upravlja čovjek (npr. preko upravljačke palice) tada čovjek zatvara petlju, tj. on prilagođava upravljanje u skladu sa stanjem sustava.

Slika 1.11. prikazuje sustav upravljanja bez povratne veze kojemu su jedini ulazi naredbe operatera. Na osnovu programiranog ponašanja i naredbi operatera sustav vremenski usklađeno šalje naredbe prema aktuatorima.

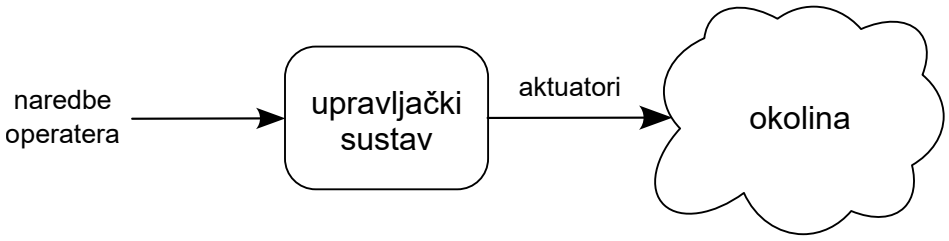

Slika 1.11. Upravljanje bez povratne veze

1.3.3. Upravljanje korištenjem povratne veze

Upravljački sustavi koji koriste povratnu vezu su bitno drukčiji od prethodnih. Slika 1.12. prikazuje načelnu shemu takvih sustava. Kod njih upravljanje izravno ovisi i o očitavanju senzora iz okoline – zasnovano je na dostupnosti tih podataka. Očitanje senzora se često radi većom frekvencijom da bi upravljački sustav istom brzinom prilagođavao upravljanje sustavom. Senzori se često ugrađuju u aktuatore da se očita njihovo stvarno stanje i usporedi s izračunatim.

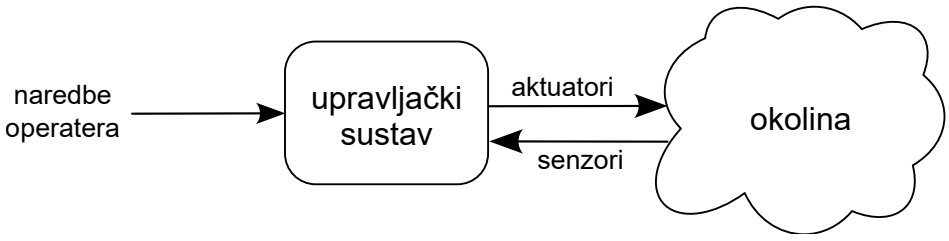

Slika 1.12. Upravljanje uz povratnu vezu

Čovjek je jedan od najboljih primjera sustava za upravljanje s povratnom vezom. Njegov je problem u sporoj reakciji koja se mjeri u desetinkama sekunde, naspram milisekundi i manje (mikrosekunde) koje nude računalno upravljani sustavi. Čovjek mu možda još može parirati

jedino u vrlo složenim sustavima npr. kod kojih treba analizirati sliku i/ili zvuk i kod kojih je dozvoljeno vrijeme reakcije bar nekoliko stotina milisekundi, jer se trenutni algoritmi (u nekom području) možda još ipak ne mogu usporediti sa čovjekom po mogućnosti prepoznavanja iako računalo svoju najbolju odluku može donijeti znatno brže, ali je možda kriva odluka. Daljnjim razvojem umjetne inteligencije vjerojatno će i u ovom području računalo nadmašiti čovjeka.

1.4. Operacijski sustavi za SRSV-e

Pri projektiranju novih SRSV-a kao jednu od prvih odluka koju treba donijeti jest izbor podloge za izgradnju, odnosno koje (mikro)računalo i operacijski sustav koristiti. U mnogim jednostavnim sustavima operacijski sustav nije ni potreban, dovoljan je upravljački program.

Često je najbolja odluka koristiti neki od komercijalno dostupnih operacijskih sustava za SRSV (engl. *real time operating system – RTOS*). Iako takva odluka može početno podići cijenu sustava, ona može značajno olakšati i ubrzati cijeli proces razvoja. Također, takvo će rješenje vjerojatno biti pouzdanije jer se takvi operacijski sustavi vrlo detaljno ispituju i već koriste u mnogim drugim sustavima. Nedostatak ovog rješenja, osim cijene, može biti krutost i nemogućnost prilagodbe posebnim zahtjevima sustava koji se izgrađuje. Primjeri komercijalnih operacijskih sustava za SRSV su *VxWorks* i *QNX*.

Alternativa komercijalnim rješenjima su besplatna rješenja kao što su *FreeRTOS* i *RTLinux*. Njihov je problem što nemaju korisničku podršku kao komercijalni i često nisu mjerljivi s njima prema svojstvima. Ipak, za ograničene primjene, mogu se i oni iskoristiti.

Treća mogućnost je izgradnja vlastitog sustava (krenuvši "od nule"). Prednosti ovog pristupa su u mogućnosti prilagodbe zadanom problemu i sustavu. Ipak, ovaj pristup treba koristiti jedino kada nema drugog izbora jer najčešće zahtjeva značajno više vremena za razvoj i ispitivanja te cijenom može znatno nadmašiti pristupe koji koriste komercijalna rješenja. S druge strane, možda upravo ovo rješenje bude najjeftinije. Sve ovisi o problemu koji se rješava.

1.5. Raspoređivanje zadataka u SRSV-ima

Složeni SRSV-i se ostvaruju korištenjem *višezadaćnosti*. Razlozi su najčešće u mogućnostima ostvarenja upravljanja i u jednostavnosti te izvedbe. Ostali načini bi jednostavno bili suviše složeni, ako bi bili i mogući. Svaka dretva u takvom sustavu obavlja pridijeljeni joj *zadatak* upravljanja pojedinim segmentom sustava. Jednoprocesorski sustavi mogu u jednom trenutku obavljati samo jedan zadatak, tj. izvoditi jednu dretvu. Višeprocesorski sustavi mogu odabrati više akrivnih dretvi – onoliko koliko ima procesora. Problem odabira dretvi za izvođenje naziva se problemom *raspoređivanja*.

Uobičajeni principi raspoređivanja dretvi u računalnom sustavu su:

- raspoređivanje prema prioritetu
- raspoređivanje po redu prispijeća
- raspoređivanje podjelom vremena.

Uobičajeno je da se u SRSV-ima pri raspoređivanju kao prvi kriterij uzima prioritet dretve, a kao drugi (kada prvi ne daje jednoznačno rješenje) red prispijeća (engl. *first-in-first-out – FIFO*) ili podjela vremena (engl. *round-robin – RR*).

Kada se raspoređivanje obavlja prema prioritetu, tada se može dogoditi i istiskivanje (engl. *preemption*) trenutno odabrane (*aktivne*) dretve drugom, prioritetnijom. Primjerice, ako se u obradi prekida dohvate podaci na koje je čekala dretva većeg prioriteta od trenutno aktivne,

ona se odblokira i istiskuje aktivnu te nastavlja s radom.

Problemi raspoređivanja u SRSV-ima jesu u specifičnim zahtjevima zadataka, tj. vremenskim ograničenjima postavljenim prema zadacima koje je potrebno zadovoljiti. Problemi su vrlo složeni i zato vrlo opsežno istraživani u znanstvenim krugovima, ali bez univerzalnog rješenja.

Najčešća praktična rješenja složenijih problema raspoređivanja uključuju predimenzioniranje, tj. korištenje bržeg sklopovlja koje će omogućiti veću zalihost procesorske snage i tako smanjiti ili ukloniti problem nemogućnosti raspoređivanja dretvi i u najkritičnijim situacijama. Dretvama se statički pridijele prioriteti prema važnosti zadataka koje obavljaju te ih operacijski sustav raspoređuje prema njima.

1.6. Primjeri SRSV-a upravljanih računalom

Zahvaljujući tehnologiji računala se sve više integriraju u našu okolinu kao *ugrađeni računalni sustavi*. Mnogi od tih sustava imaju značajke i SRSV-a.

Primjeri nekoliko SRSV-a koji značajno utječu na nas i našu okolinu su:

- u vozilima:
  - sustavi pomoći pri kočenju i slični sustavi za sprječavanje proklizavanja
  - upravljanje radom motora radi smanjene potrošnje ili povećane snage
  - sustav održavanja brzine i razmaka između vozila
  - napredni sustavi detekcije prepreka te samostalnog zaustavljanja vozila
- u vojnoj industriji:
  - za prepoznavanje objekata
  - navođenje letjelica i projektila
  - obradu i prikaz informacija (za pilota, za voditelje timova, ...)
- za upravljanje robotima (robotskim rukama):
  - u medicinske svrhe (operacije, pregledi)
  - u prometu (skretnice, rampe)
  - u industrijskim postrojenjima
  - za upravljanje alatnim strojem
  - za rad na traci (više robota, njihov usklađen rad)
  - za upravljanje (kemijskim) procesom gdje postoji opasnost za čovjeka
- za upravljanje većim složenim sustavima:
  - avioni (sakupljanje i obrada podataka te upravljanje)
  - elektroenergetski sustav, od upravljanje elektranama i svim njenim procesima do raspodijele električne energije.

U okviru predmeta neće se razmatrati prethodni složeni sustavi jer bi za njihovo razmatranje trebalo najprije dobro razumjeti njihovu okolinu (npr. trebalo bi proučiti osim načina prikupljanja podataka i njihove utjecaje – trebalo bi razumjeti proces, ne samo s programerskog gledišta).

Ipak, u okviru prikaza postupaka koristit će se dijelovi raznih sustava, primjerice problem upravljanja liftom.

1.7. Problem složenosti

Većina sustava je složeno. Što je sustav složeniji to ga je teže razumjeti i lakše je napraviti greške, teže je uočiti odnose među komponentama, shvatiti način rada, redoslijed obavljanja neke aktivnosti i slično. Slika 1.13. prikazuje složeni sustav s jako puno veza između njegovih dijelova.

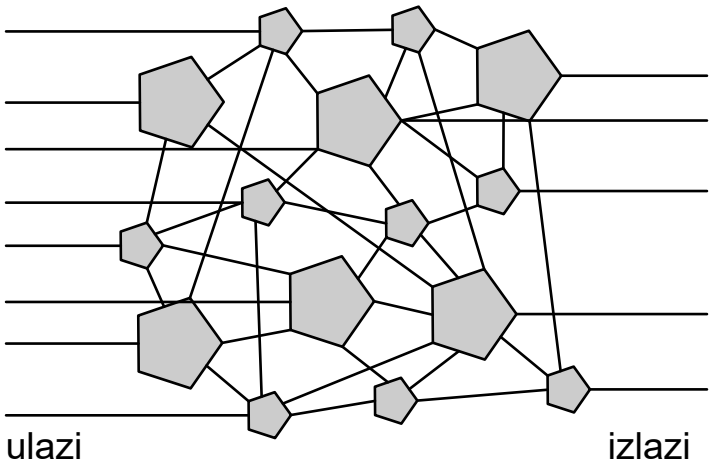

Slika 1.13. Složeni sustav

Upravljanje mora uzeti u obzir mnoštvo komponenti koje treba uskladiti, odabrati odgovarajuće komunikacijske protokole, kako za komponente koje izravno čine sustav (npr. senzori, aktuatori), tako i za one udaljenije koje pružaju odgovarajuće usluge (npr. servisne informacije, poslužuje zahtjeve klijenata). Pri projektiranju pojedine komponente treba uzeti u obzir ne samo njenu osnovnu namjenu (upravljanja ili nadzora) već i načine na koje se ta komponenta povezuje i integrira s ostatkom sustava.

Ako se za primjer uzme automobil, onda se može utvrditi da se upravljanje sve više i više prebacuje na elektroničko, gdje čovjek preko ulaznih naprava komunicira s računalom, a koje onda upravlja automobilom. Upravljački sustav automobila sastoji se od senzora koji daju informacije te aktuatora koji provode akcije. Primjerice, u senzore se mogu uključiti: volan, pedale (gas, kočnicu, kvačilo), ručica mjenjača, ručna kočnica, senzori u motoru (stanje komponenti, kao što su temperatura, tlak), senzori na kotačima, senzori okoline (temperatura, podloga, osvjetljenje, vlažnosti), senzori položaja i smjera (npr. preko GPS signala), senzori u kabini, podaci o svojstvima motora, mape za navođenja i slično. Aktuatori upravljaju smjerom kretanja, motorom, kočnicama, svjetlima, klima uređajima, zračnim jastucima, alarmom i slično. Svaka od navedenih komponenti je zasebni podsustav sa svojim svojstvima i vremenskim ograničenjima. Gotovo sve komponente su integrirane u automobil, ali mogu se koristiti i informacije iz udaljenih sustava, kao što su GPS i prometne informacije. Ovakav raspodijeljeni sustav je samo jedan primjer današnjih složenih sustava.

Sustav ili samo jedna njegova komponenta koja se nadzire ili kojom se upravlja može biti različite složenosti. Složenost je svojstvo sustava koji treba izgraditi (problema koji treba riješiti) i ne bi trebala biti povećana predloženim rješenjima. Ako za neki problem postoji nekoliko mogućih rješenja, treba nastojati izabrati *najjednostavnije*, to je jedan od osnovnih ciljeva. Npr. ako se upravljanje može ostvariti samo s jednom jednostavnom petljom, onda tako treba napraviti.

U većini slučajeva, najjednostavnije moguće rješenje je najbolje rješenje.

Iznimno, zbog nekih drugih razloga kao što su sklopovski zahtjevi, bolje mogućnosti proširenja i održavanja, može se odabrati i neko drugo (složenije) rješenje.

U većim projektima složenost je među najvećim problemima. SRSV-i koji zahtijevaju znatno strože kriterije u gotovo svim pogledima (pogotovo otklanjanje pogrešaka), posebno su osjetljivi na složena rješenja. Zato je od iznimnog značaja da projektanti takvih sustava, kao i oni koji kasnije sudjeluju u njegovoj izgradnji, jako dobro poznaju metode koje se koriste pri analizi te da znaju odabrati prave algoritme za rješavanje problema. "Pravi" algoritam treba biti dostatan za rješavanje problema ali također treba biti što je moguće manje zahtjevan na sklopovlje. Nije uvijek prikladno odabrati najbolji/najprecizniji/najopćenitiji algoritam jer on može značajno poskupiti izradu sustava, tj. tražiti korištenje skupljeg računala.

Svaki je sustav poseban, po nečemu različit od drugih. Stoga i rješenja koja se primjenjuju u jednom sustavu ne moraju biti tako uspješna u drugom, ili čak mogu biti neprikladna. Da bi donijeli prave odluke projektanti trebaju poznavati osnovne načine ostvarenja sustava, ali i uobičajene postupke korištene u praksi ("postupke dobre inženjerske prakse"). Najbolje bi bilo kada bi oni već imali iskustva s različitim sustavima te bi usporedbom s onim kojeg treba izgraditi mogli odrediti koji su postupci primjereni. U nedostatku vlastitog iskustva mogu se pogledati i primjeri iz literature što se preporuča za korištenje u sličnim projektima.

Za odabir prikladnog postupka potrebno je jako dobro upoznati sustav koji se izgrađuje (i kojemu se dodaje upravljačka komponenta) te način njegova željena rada. Postoje mnogi postupci specifikacije sustava i načina njegova rada, uključujući i standardizirane (npr. *UML dijagrami*) i formalne (npr. formule, formalna logika), a čiji je osnovni cilj bolje razumijevanje sustava od strane sudionika u njegovoj izgradnji. Prednost standardiziranih i formalnih načina specifikacije jest u tome što ih svi jednako interpretiraju i što ih se može iskoristiti za analizu korištenjem prikladnih alata. Prednost grafičkih postupaka jest u jednostavnijem razumijevanju od strane čovjeka, kojemu vizualna slika može znatno pomoći da shvati sustav ili njegove dijelove i način rada.

Postupke koji pomažu u analizi, oblikovanju i izgradnji mogli bi podijeliti prema fazi u kojoj se koriste, prema tome tko ih koristi, prema problemu koji obrađuju, prema arhitekturama kojima su namijenjeni i slično. U 2. poglavlju navedeni su neki od tih postupaka, s naglaskom na primjenu u SRSV-ima.

1.7.1. Grafički postupci modeliranja sustava

Među poznatije grafičke postupke prikladne i za SRSV-e spadaju UML dijagrami:

- *dijagrami obrazaca uporabe* i *sekvencijski dijagram* za analizu sustava (interakcije, željeno ponašanje),
- *dijagram stanja* i *dijagram aktivnosti* za analizu mogućeg rada te
- ostali UML dijagrami za detaljnije razmatranje mogućeg ostvarenja i ponekog detalja.

Osim UML dijagrama, za analizu i ispitivanje mogućih rješenja prikladne mogu biti *Petrijeve mreže* i *vremenske Petrijeve mreže*.

Pri pojedinačnoj analizi (početku analize) mogu se koristiti i *neformalne skice*, ali bi one prije ulaska u službenu dokumentaciju (i dijeljenja s ostatkom tima) ipak trebale biti prevedene u neki formalni oblik, a da se izbjegne mogućnost krive interpretacije.

1.7.2. Metoda “podijeli i vladaj”

Uobičajeni postupci smanjenja složenosti zasnivaju se na načelu *podijeli i vladaj*. Ovo je prvo načelo u temeljnim načelima oblikovanja arhitekture zato što je i najvažnije. Odgovarajuća podjela će značajno olakšati razumijevanje sustava i smanjiti utjecaj složenosti sustava kao cjeline. Slika 1.14. prikazuje moguće pojednostavljenje sustava sa slike 1.13.

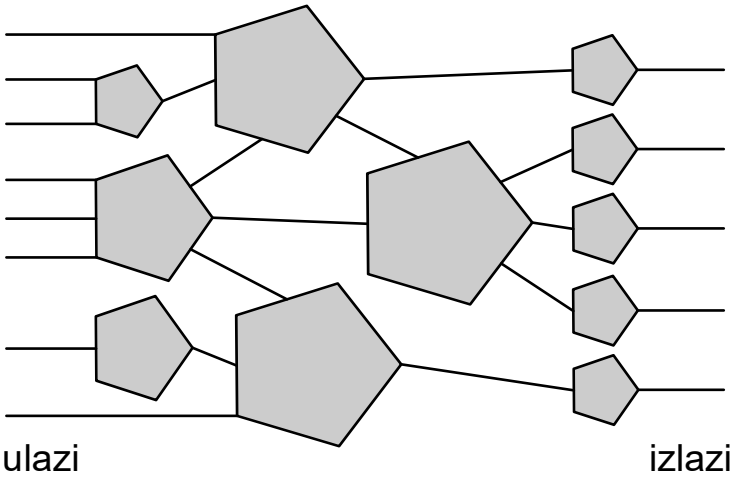

Slika 1.14. Sustav podijeljen na dijelove

Podjela se može napraviti na mnoštvo načina. Često se i za jedan sustav/problem radi više podjela. Primjerice, operacijski sustav može se podijeliti na slojeve: sloj sklopovlja, sloj jezgre, sloj primjenskih programa, ali i na komponente (tj. podsustave): upravljanje napravama, upravljanje spremnikom, upravljanje dretvama, datotečni podsustav, mrežni podsustav itd. Podjele mogu biti ostvarene na razini izvornih kôdova ili na razini izvođenja ili na razini povezivanja s drugim raspodijeljenim programima.

Pravilnom podjelom nastaju dijelovi (slojevi, komponente, razine) koji su zasebno značajno jednostavniji od cijelog sustava. Zato su i čovjeku razumljiviji te ih on može bolje osmisliti (npr. bit će brži, manji, smanjit će se broj grešaka). Druga prednost podjele jest što se pojedini dio može pridijeliti zasebnom inženjeru ili timu koji će se njemu posvetiti (analiza i/ili oblikovanje i/ili programiranje). Komunikacija s drugim dijelovima mora biti identificirana i uobličena u dobro definirano *sučelje*.

U ostvarenju upravljanja složenim sustavima podjele se mogu ostvariti i prema *hijerarhijskim razinama* i na *dretve* koje surađujući upravljaju sustavom.

Nedostaci korištenja metode podijeli i vladaj mogu se pojaviti u sustavima s očekivanom visokom učinkovitošću, gdje dodatni slojevi, razine i slično unose dodatne poslove (npr. svaki sloj ima svoje omotače koje dodaje na poruku prethodnog sloja). U takvim se sustavima može ‘tunelirati’ kroz slojeve, tj. izbaciti neke slojeve ugrađujući potrebne operacije na jednom mjestu (jednom sloju).

1.8. Uobičajeni pristupi ostvarenja upravljanja

Svaki je sustav po nečemu poseban, traži bar malo dorade u odnosu na neki sličan. Ipak, ako se na kraju pogledaju zahjevi prema sustavu sa stanovišta upravljanja, ti se zahtjevi uglavnom mogu podijeliti u dvije kategorije:

1. reakcija na vanjske događaje te

2. periodički poslovi.

Brza reakcija na vanjske događaje se može ostvariti na razne načine. Jedan je korištenjem mehanizma prekida koji će odmah po pojavi događaja izazvati reakciju (započeti njenu obradu). Drugi je korištenjem petlje u kojoj se neprestano provjerava stanje okoline te se na taj način otkriva događaj (i potom obrađuje).

Periodičke akcije u kojima se pokreću neke operacije, očitavaju i obrađuju senzori i slično mogu se ostvariti na razne načine, od upravljačke petlje, programiranih alarma (akcija u budućnosti) do korištenja zasebnih dretvi za svaku periodičku aktivnost. Svaki od načina ima svoje prednosti i nedostatke te područja primjene.

U idućim poglavljima (posebice od 3. na dalje) se detaljnije prikazuju mehanizmi za ostvarenje upravljanja obje kategorije zahtjeva, svaki sa svojim prednostima i nedostatcima te mogućim područjima primjene.

1.9. Zašto proučavati SRSV-e?

Ugrađeni SRSV-i, barem oni jednostavniji su svuda oko nas, čak i u jednostavnijim igračkama i kućanskim aparatima. Dobar dio tih sustava koristi mikroprocesor kao osnovnu upravljačku jedinicu koja za upravljanje koristi programe. U budućnosti će se broj takvih sustava samo povećavati te će i potrebe za njihovo projektiranju i izgradnju rasti. Više znanja o takvim sustavima je svakako potrebno inženjerima koji će se u takve projekte upuštati.

Projektiranje i ostvarenje SRSV-a zahtjeva značajno dublje razmatranje problema u usporedbi s aktivnostima za ostvarenje drugih sustava. Posebno su bitne aktivnosti za projektiranje sustava koje uključuju:

- odabir sklopovskih i programskih komponenti koje će zadovoljiti zahtjeve uz primjerenu cijenu
- odabir (komercijalno) dostupnog operacijskog sustava ili projektiranje vlastite jezgre
- odabir razvojnih alata (uključujući i programske jezike)
- maksimiziranje otpornosti na greške i povećanje pouzdanosti prikladnim postupcima projektiranja i ispitivanja
- oblikovanje, planiranje i izvođenje ispitivanja tijekom cijelog procesa razvoja sustava.

Predviđanje ponašanja sustava, očitovanje njegova ponašanja, uočavanje *vremena reakcije* te postupci njegova smanjenja su temeljne operacije koje treba provoditi pri izgradnji SRSV-a. Znanje stečeno proučavanjem SRSV-a, odnosno prethodno navedenih aktivnosti će se moći iskoristiti i kod običnih sustava. Stečeno znanje moći će se iskoristiti za izgradnju kvalitetnijih sustava, s manje kôda, veće brzine, pouzdanosti i slično.

Pitanja za vježbu 1

1. Koje značajke odvajaju sustave za rad u stvarnom vremenu od ostalih sustava?
2. Što je to logička a što vremenska ispravnost (programa, sustava)?
3. Opisati “stroge”, “ublažene” i “čvrste” SRSV-e.

4. Što je najbitnije za SRSV-e koji svoje upravljanje temelje na obradi događaja?
5. Najčešća ocjena nekog sustava s aspekta stvarnog vremena jest u pogledu reakcije na događaje. Kakvi se sve događaji razmatraju te kakva treba biti reakcija SRSV-a?
6. Zašto svaki operacijski sustav nije pogodan za SRSV-e?
7. Zašto bilo kakvo sklopovlje nije prikladno za korištenje u SRSV-ima?
8. Opisati atribute: determinizam, pouzdanost i robusnost u kontekstu SRSV-a.
9. Kako se upravlja diskretnim, a kako kontinuiranim sustavima?
10. Usporediti upravljanje koje ne koristi povratnu vezu s onim koje koristi.
11. Koji je osnovni razlog prisutnosti grešaka u programima?
12. Zašto je “problem složenosti” najveći problem pri izgradnji SRSV-a? Koji se postupci koriste radi smanjenja složenosti?

2. Modeliranje sustava

Osnovni razlog korištenja modela je složenost stvarnih sustava. Model je pojednostavljeni prikaz sustava s određene perspektive, zanemarujući neka druga svojstva sustava. Korištenjem modela mogu se lakše razaznati svojstva sustava, uočiti problemi i slično.

U postupku projektiranja sustava treba odlučiti *kako* nešto napraviti, povezati, ispitati, i slično. Postupci određivanja prikladnih metoda (koje će reći *ovako*) su vrlo različiti i ovise o projektantu, tj. njegovom poznavanju raznih postupaka i rasuđivanju o njihovoj prikladnosti. Postupci mogu biti *neformalni* ili zasnovani na nekom standardiziranom, *formalnom* načinu oblikovanja.

U nastavku će se prikazati moguća uporaba oba tipa postupaka na primjeru projektiranja hipotetske upravljačke komponente za *lift u zgradi*.

2.1. Neformalni postupci

Neformalni postupci omogućuju jednoj osobi brži pristup do rješenja korištenjem (samo) njoj prikladne metode. *Skica* koju je projektant sebi na brzinu nacrtao (npr. rukom na papiru) možda će mu omogućiti da bolje vizualizira problem i riješi ga brže nego da primjerice za isto koristi komunikacijski *UML*-dijagram za koji će mu trebati puno više vremena da ga nacrta.

Problemi neformalnih postupaka su upravo u njihovoj neformalnoj strukturi koja se na različite načine može interpretirati i time dovesti do problema. Ipak, ako se koriste samo kao pomoćno sredstvo pri rješavanju dijela problema mogu značajno olakšati razumijevanje problema ili predloženog rješenja.

2.1.1. Skica

Slika 2.1. prikazuje primjer skice zgrade i sučelja prema liftu, koja može olakšati početno shvaćanje problema. Vrijeme potrebno za izradu ovakve skice je svega par minuta, a njena korisnost za početnu analizu može biti znatna.

Slične potrebe mogu nastati i za druge elemente sustava, za analizu prikladnosti algoritama (izvođenjem na primjeru), skicu stanja sustava u nekom trenutku i slično. Prednosti skice su:

- nastaje u vrlo kratkom vremenu
- omogućuje prikaz različitih elemenata (koji se u formalnim oblicima ne stavljaju zajedno)
- nisu potrebni nikakvi alati.

Skica u neformalnom obliku bi trebala biti samo privremeno sredstvo u nekoj fazi razvoja i ne bi smjela biti dio dokumentacije. Zapravo, svim "formalnim" postupcima može prethoditi ovakva skica koja će olakšati izradu formalnih. Npr. u ozbiljnijim projektima prethodna slika će se nacrtati pravim alatima i postupcima (nacrt zgrade s ucrtanim liftom u pravom mjerilu, panel kao elektronička komponenta, ...) i kao takva ući u dokumentaciju (a ne u ovakvom obliku kao na slici 2.1.).

Osim grafičkog prikaza u obliku skice, neformalni postupci obuhvaćaju i druge oblike, npr. definiciju problema običnim tekstom.

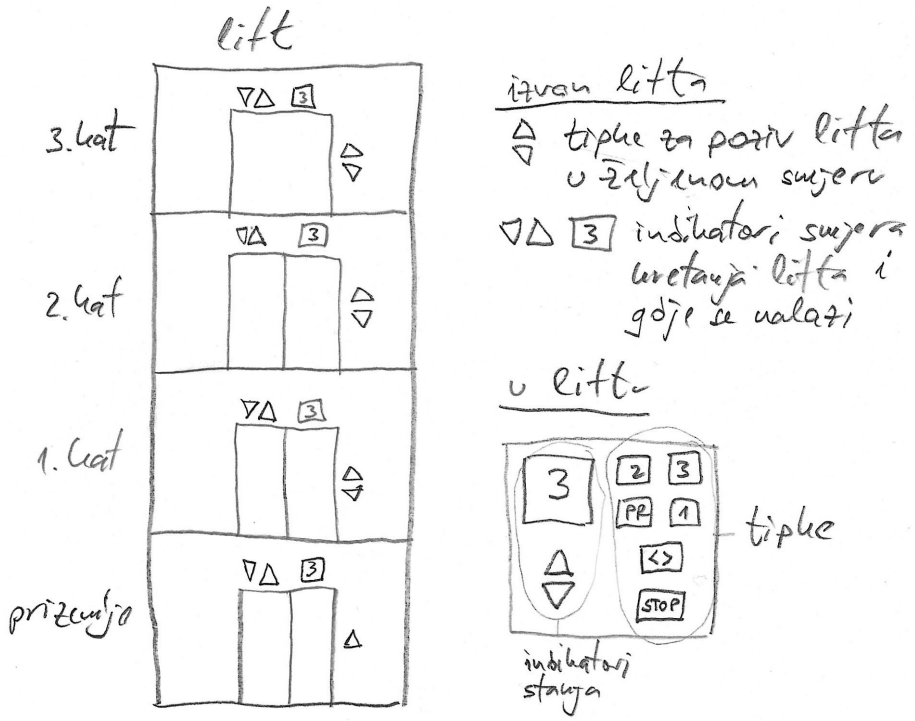

Slika 2.1. Skica lifta u zgradi sa sučeljima za korisnike

2.1.2. Tekstovni opis

Početna definicija problema se najčešće zadaje tekstovnim opisom. Npr. za lift, početni opis može biti zadan tekstom u *prirodnom jeziku* prema primjeru 2.1.

Primjer 2.1. Primjer tekstovnog opisa

Zadatak: *Projektiranje upravljačkog sustava za liftove*

Opis:

Projektirati upravljački sustav za liftove koji se ugrađuju u zgrade s tri do osam katova.

Sučelje prema korisnicima:

Na svakom katu u blizini vrata lifta trebaju biti dvije tipke za poziv lifta prema gore i prema dole, osim na zadnjim katovima gdje je dovoljna jedna tipka. Kad se takva tipka stisne ona treba svijetliti sve dok lift ne stigne na taj kat, stane na njemu, otvori vrata te se namjerava dalje kretati u zahtjevanom smjeru.

Iznad ulaza u lift trebaju biti indikatori smjera kretanja lifta, za gore i za dole te prikaz trenutnog kata na kojem se lift nalazi.

U liftu se treba nalaziti panel s tipkama i indikatorima: za svaki kat treba postojati zasebna tipka koja će svijetliti ako je stisnuta (a označava da će lift stati na tom katu), prikaz trenutnog kata gdje se lift nalazi, prikaz smjer gibanja lifta (ništa, gore, dole), sklopka za trenutno (hitno, ručno) zaustavljanje lifta (STOP), tipka zahtjeva za ponovno otvaranje vrata kada lift stoji na katu (<>), tipka zahtjeva za pomoć (npr. kad se lift pokvari i ne ide dalje).

Ponašanje lifta

Kada lift stoji besposlen, on stoji na nekom katu sa zatvorenim vratima. Prvi zahtjev koji tada naiđe treba ga pokrenuti. Kada je to pritisak na tipku u liftu ili pritisak na tipku s nekog kata, lift treba otići na traženi kat te otvoriti vrata. Ako zahtjev dođe za vrijeme pomicanja lifta, lift treba stati na traženom katu ako je taj kat na putu kojim lift ide i ako se taj zahtjev može obraditi daljnjim pomicanjem lifta u istom smjeru. Inače se zahtjev poslužuje naknadno, kad lift posluži zahtjeve u trenutnom smjeru.

Pritisak na tipku OTVORI treba razmatrati dok lift stoji sa zatvorenim vratima ili su ona u postupku zatvaranja ili su otvorena. U tim slučajevima treba prvo pokrenuti otvaranje vrata, ako već nisu otvorena. Ako su vrata već otvorena, treba produljiti stanje s otvorenim vratima (kao da su vrata tek otvorena).

Pri analizi tekstom zadanog zadatka projektant će si skicirati moguće rješenje, npr. prema slici 2.1. U ovoj fazi analize zahtjeva neki su zahtjevi izravno ucrtani u skicu, a drugi koji su samo načelno zadani su već početno i osmišljeni. Primjerice, indikatori smjera gibanja liftova koji se nalaze na svakom katu su dvije odvojene žaruljice (po katu) te 7-segmentni indikator trenutnog položaja lifta.

Čest se već na skici mogu uočiti mogući problemi ili nedorečenosti te možda i odmah na skicu nadodati rješenje. Primjerice, kako označavati kat na kom se lift trenutno nalazi. Na skici sa slike 2.1. je tamo nacrtan broj, ali kako ga ostvariti? Da li koristiti jednostavni (jeftin) 7-segmentni indikator ili žaruljicu za svaki kat ili složeniji panel na kojem se može lijepše prikazati broj kata. Svako rješenje ima svoje prednosti i nedostatke te treba, možda čak i za konkretnu ugradnju, odabrati prikladno rješenje.

2.1.3. Dijagram stanja

Iako dijagram stanja posjeduje formalne elemente (stanja, prijelazi), u neformalnom razmatranju na njega se mogu staviti i drugi elementi. Primjerice, pri razmatranju ostvarenja upravljačke komponente, projektant je možda prvo napravio stanja kao na slici 2.2.

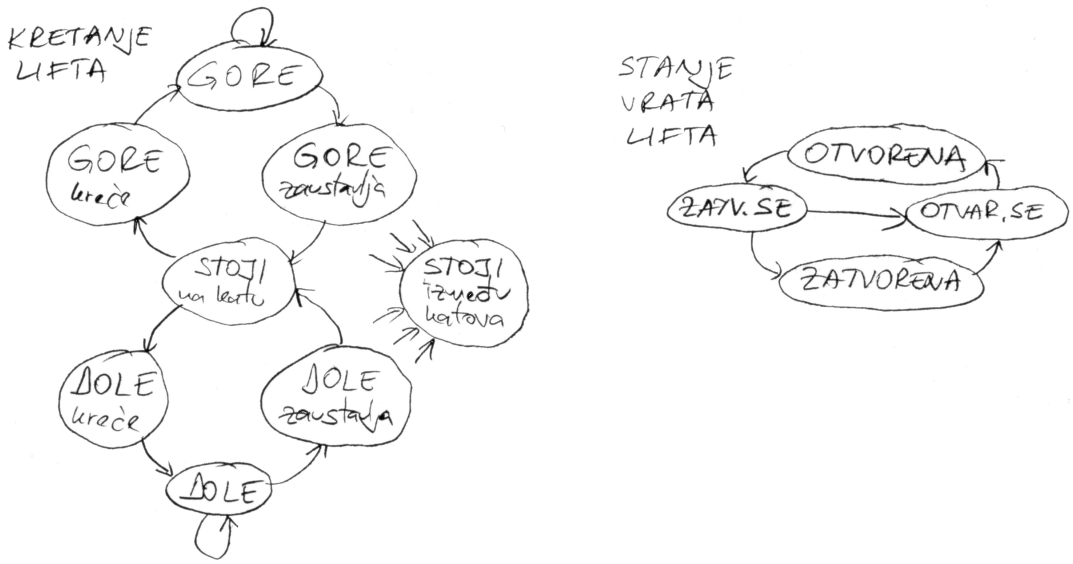

Slika 2.2. Dijagram stanja lifta, vrata u liftu i vrata na katu

Stanje označeno sa *STOJI između katova* označava da se iz svih stanja može preći u to stanje. Iako se to može nacrtati i strelicama iz svih ostalih stanja, te strelicama iz tog stanja u sva ostala

(kad se otpusti hitno stajanje), to bi crtanje učinilo dijagram osjetno složenijim. Hitno stajanje je posebno stanje za koje treba drukčije reagirati u odnosu na sva ostala stanja i događaje. Stoga ima smisla to stanje izdvojiti i ne uključivati ga u dijagram kojemu je osnovna namjena osmisliti algoritam za upravljanje u uobičajenim okolnostima. Njegovo prisustvo na dijagramu, iako izdvojeno, može poslužiti da se i pri osmišljavanju algoritma za uobičajene okolnosti ipak postupno razmišlja i o problemu hitnog zaustavljanja.

Daljnjom analizom dijagrama stanja sa slike 2.2. moguće je vrlo brzo napraviti analizu, otkriti moguće probleme te napraviti "poboljšani" dijagram. Primjerice, umjesto zasebnih stanja za *gore* i *dolje*, može se napraviti novi dijagram, koji informaciju o smjeru kretanja lifta ne pokazuje u dijagramu već u dodatnoj strukturi podataka (tamo će među ostalima biti i trenutni vertikalni položaj lifta). Primjer takvog dijagrama prikazuje slika 2.3.

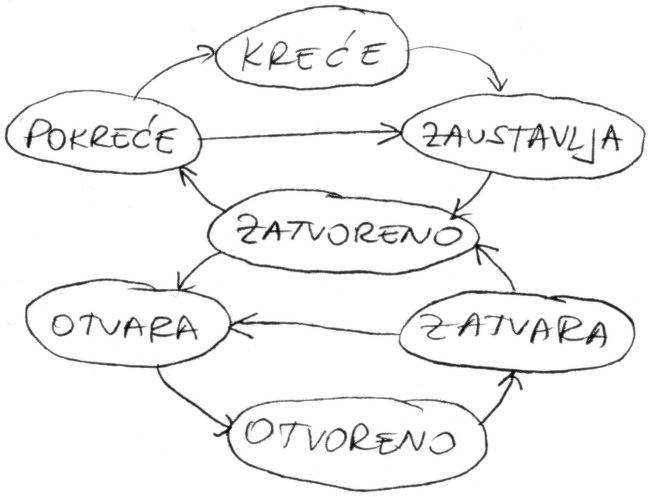

Slika 2.3. Dijagram stanja lifta, nakon spajanja

2.1.4. Nedostaci neformalnih postupaka

Osim navedenih postupaka, skice, tekstovnog opisa i dijagrama stanja, mogu se koristiti i drugi neformalni postupci, npr. pseudokôdom opisati neku operaciju. Izgradnja jednostavnih nekritičnih sustava može biti zasnovana i na jednostavnoj analizi takvim postupcima. Ako programsku komponentu razvija jedna osoba ili mali broj osoba, i jednostavna skica i opis tekstom mogu biti dovoljni.

Za kritične sustave i za složenije sustave samo osnovna analiza (npr. neformalnim postupcima) uglavnom neće biti dostatna. Osnovni problem jest složenost i naša nemogućnost da ju savladamo na razini cijelog sustava. Zato se koriste modeli, da podjele sustav i da prikažu sustav iz pojedinih perspektiva. Neformalni postupci pomažu u tome, ali niti su dovoljno precizni (ne mogu se svi detalji postaviti na skice) niti se jednako interpretiraju od različitih projektanata. Čak i ista osoba koja je napravila skicu može ju naknadno na drugi način interpretirati, npr. zbog potrebnih proširenja koji su se pojavili mjesecima i godinama nakon početne izrade. Neki problemi se neće uočiti sve do kasne faze projekta kada će biti puno teže prilagoditi sustav ili će se oni pokazati tek u radu sustava i pritom prouzročiti ozbiljne probleme. Naknadno ispravljanje sustava (npr. programske potpore) često će uzrokovati narušavanje arhitekture sustava, koja posljedično otežava nadogradnje i održavanja te ukupno znatno podiže cijenu sustava.

Neformalne postupke zato treba koristiti ograničeno, npr. pri osmišljavanju mogućih rješenja nekih problema u bilo kojoj fazi razvoja. Pri temeljitijoj analizi treba ih izbjegavati jer oni

ne posjeduju potrebnu razinu detalja. Također, zbog neformalnosti, razni sudionici ih mogu različito shvaćati što vodi do problema u njihovoj međusobnoj komunikaciji.

2.2. Formalni postupci u oblikovanju sustava

Za većinu prethodnih neformalnih postupaka postoje odgovarajući formalni, propisani standardima. Iako će slika sustava kojim se upravlja biti od velike koristi, odnosi u sustavu se mogu detaljnije i jednoznačnije prikazati formalnim oblicima, kao što su UML-dijagrami.

U detaljnijim analizama i postupcima pronalaska ispravnog rješenja mogu se koristiti i Petrijeve mreže te vremenske Petrijeve mreže, gdje je vrijeme jedan od bitnih pokretača promjena ili je bitno da se poštuju zadana vremenska ograničenja. Za modeliranje ponašanja sustava često se koriste i automati stanja (engl. *Finite State Machines*), ali se oni ovdje ne razmatraju.

U nastavku su navedena osnovna svojstva UML-dijagrama i Petrijevih mreža te prikazano njihovo korištenje na primjerima vezanim uz problem ostvarenja upravljanja liftom te drugim problemima.

2.2.1. UML-dijagrami obrazaca uporabe

Identifikacija usluga/operacija, korisnika usluga i komponenata sustava se može prikazati UML-dijagramom obrazaca uporabe (engl. *use case*).

Izrada dijagrama ovisi o tome što se želi prikazati i analizirati. Ako su to operacije upravljačkog računala na zahtjev putnika ili stanja lifta, može se izgraditi UML-dijagram obrazaca uporabe kao na slici 2.4. Svaka se operacija može detaljnije opisati tekstom ili nekim drugim dijagramima, npr. sekvencijskim i komunikacijskim. Primjerice, pomicanje lifta uključuje dohvat trenutnog položaja i stanja lifta te postojećih zahtjeva putnika.

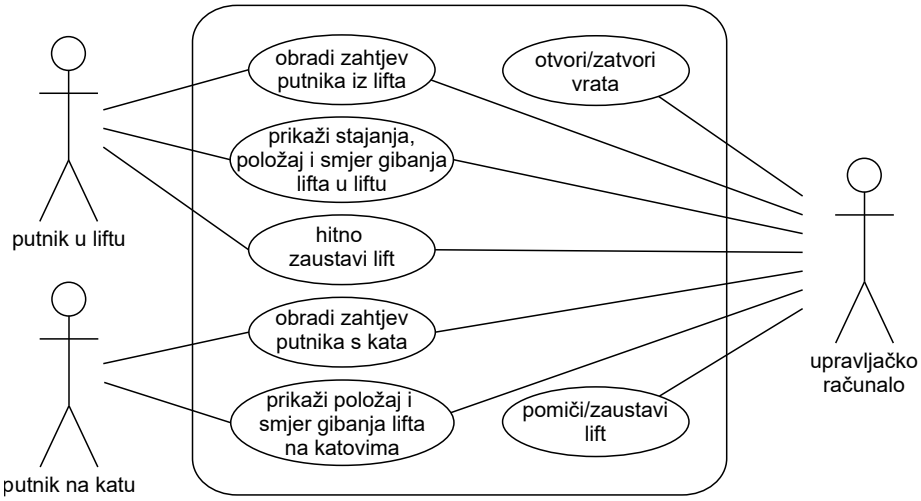

Slika 2.4. Primjer UML-dijagrama obrazaca uporabe

2.2.2. Sekvencijski i komunikacijski UML-dijagrami

Scenariji slijeda aktivnosti u vremenu se osim prirodnim jezikom mogu prikazati i grafički, primjerice sekvencijskim dijagramom. Tko s kim komunicira najlakše je uočiti iz komunikacijskog dijagrama.

Sekvencijski dijagrami se često koriste pri projektiranju i analizi SRSV-a zbog mogućnosti prikaza vremenskog uređenja događaja i akcija. Primjerice, ako treba analizirati akcije i poruke koje se zbivaju od zahtjeva putnika s jednog kata do dolaska lifta na taj kat, može se izgraditi sekvencijski dijagram prema slici 2.5.

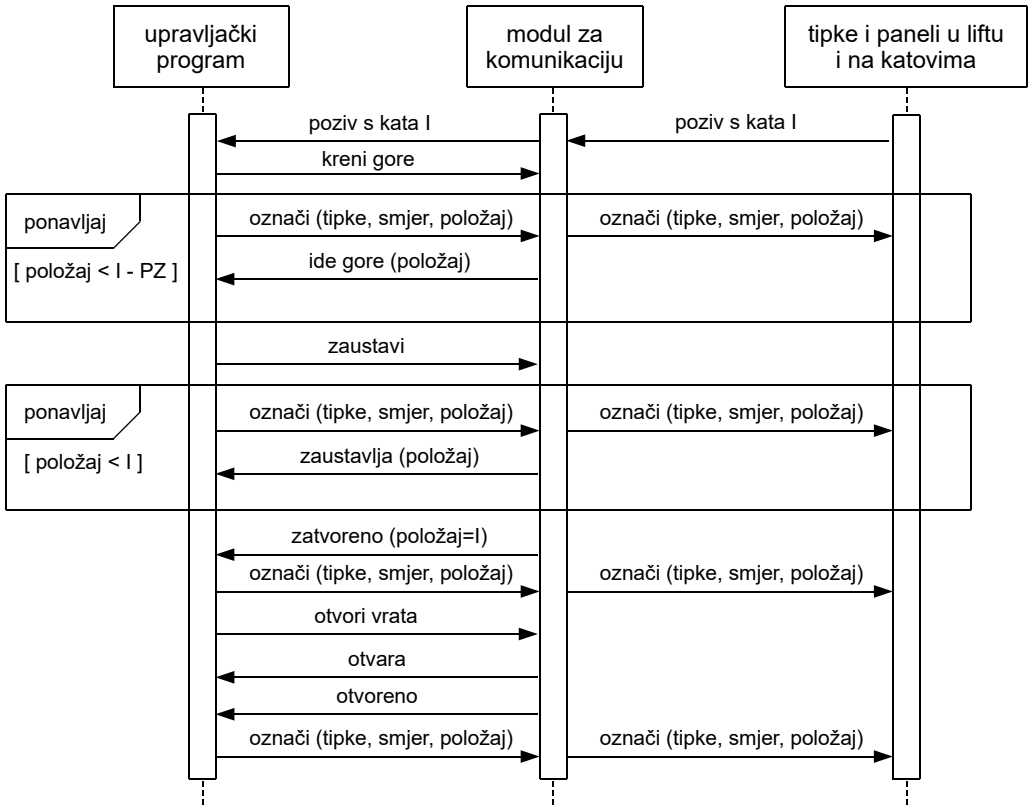

Slika 2.5. Primjer sekvencijskog UML-dijagrama

Dijagram obrazaca uporabe, sekvencijski i komunikacijski dijagrami su, osim za postupke analize, prikladni i za izradu početnog dokumenta specifikacije te za pisanje tehničke dokumentacije.

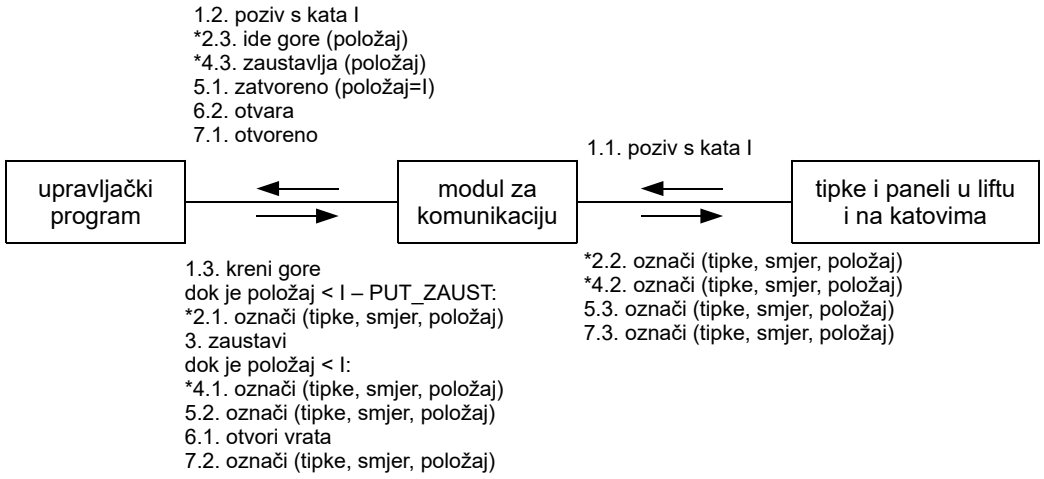

Slika 2.6. Primjer komunikacijskog UML-dijagrama

2.2.3. UML-dijagram stanja

UML-dijagram stanja jest proširenje običnog dijagrama stanja koji dozvoljava detaljniji prikaz uzroka i posljedice pojedinih stanja i događaja. Dijagram stanja iz primjera 2.3. za kretanje lifta se može zapisati u formalnom obliku pomoću UML-dijagrama stanja, pritom dodajući i dodatne informacije, npr. poruke koje treba poslati pri ulasku u pojedino stanje, npr. prema slici 2.7.

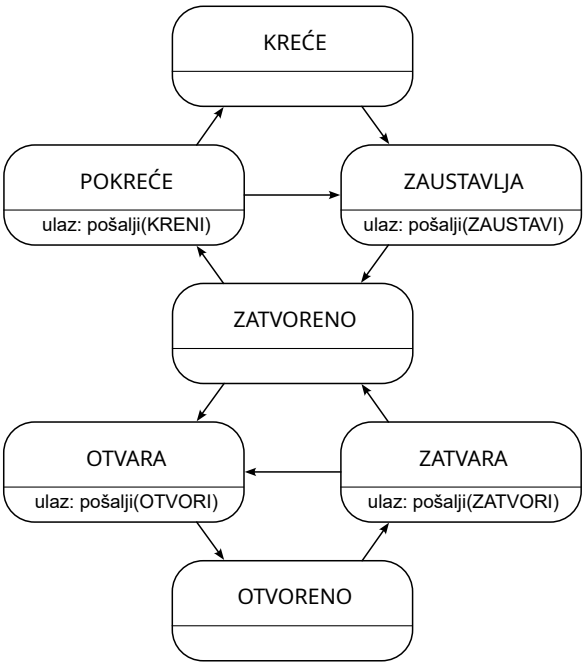

Slika 2.7. Primjer UML-dijagrama stanja

Kada su prijelazi većinom uzrokovani dovršetkom određenih procesa, primjereniji dijagram jest dijagram aktivnosti, koji za razliku od dijagrama stanja pruža više mogućnosti za prikaz paralelnih aktivnosti. UML-dijagrami mogu uključivati mnoge dodatne informacije, kao što je pokretanje aktivnosti pri ulasku u stanje. Većinom su dodatne informacije u UML-dijagramu dobrodošle, posebice pri izradi tehničke dokumentacije. Međutim, u procesu analize treba biti pažljiv s dodavanjem detalja jer će oni smanjiti čitljivost dijagrama, a osnovna namjena dijagrama u toj fazi je povećanje razumijevanja i uočavanje mogućih problema u arhitekturi, komunikaciji i slično.

Složenija programska rješenja koja koriste podsustave, komponente i različite programe mogu se vizualizirati dijagramom komponenata te dijagramom ugradnje ako su te komponente na raspodijeljenim računalima.

2.2.4. Petrijeve mreže

Petrijeve mreže su sredstvo za vizualizaciju i analizu dinamičkih procesa u sustavima s više aktivnih komponenata (procesa, dretvi, poruka, . . .). Nazvane su prema Carlu Adamu Petriju koji ih je osmislio i prvi put koristio 1939. godine. Petrijeve mreže po izgledu su slične usmjerenim grafovima, ali je semantika prijelaza iz stanja u stanje proširena. Petrijeve mreže se koriste u raznim područjima, primjerice kod paralelnog programiranja, analize podataka, modeliranja procesa, procjene pouzdanosti, oblikovanja programske potpore i simulacije sustava.

Petrijeve mreže sastoje se od tri osnovna elementa:

- *mjesta* (stanja, engl. *state/places*),

- *prijelaza* (tranzicija) i
- *znački* (engl. *token*) koji prelaze iz jednog mjesta u drugo (ili isto) preko prijelaza.

Veze između mjesta i prijelaza te prijelaza i novog mjesta su označene *vezama*. Veze mogu biti *normalne* (težine 1), s pridijeljenom težinom npr. *N* te *inhibicijske veze* (težine 0). Veze također mogu biti *ulazne* (značke preko njih dolaze u mrežu) te *izlazne* (značke odlaze iz mreže).

U Petrijevoj mreži može istovremeno postojati više znački, od kojih svaka predstavlja neko sredstvo, komponentu ili slično. Slika 2.8. prikazuje jednu Petrijevu mrežu s naznačenim elementima mjesta, prijelaza, znački, veze s težinom N te inhibicijske veze. U prikazanom primjeru su stanja i prijelazi označeni simbolima S_0, S_P i S_{ITER} te p_1, p_2 i p_3, ali oni nisu obavezni.

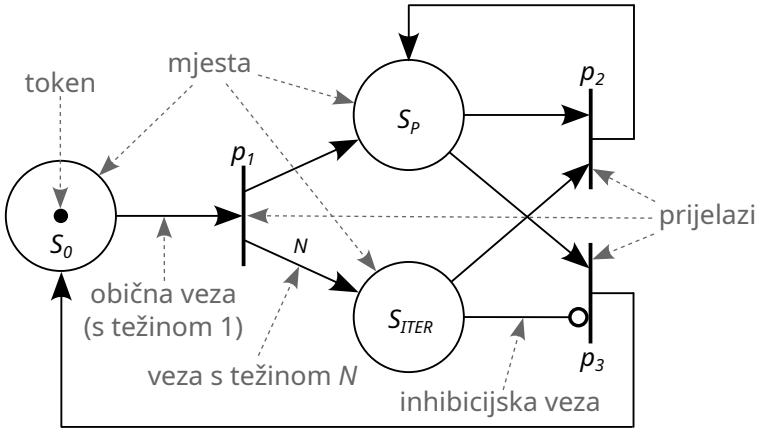

Slika 2.8. Primjer Petrijeve mreže

Da bi se pojedini prijelaz aktivirao, tj. obavio prijenos značke, sve ulazne veze (do prijelaza) moraju biti spremne za prijelaz, tj. odgovarajući broj znački mora biti u polaznim stanjima. Za prijelaz p_1 barem jedna značka mora biti u mjestu S_0; za prijelaz p_2 stanja S_P i S_{ITER} moraju imati barem po jednu značku, dok za prijelaz p_3, koji ima jednu ulaznu inhibicijsku vezu, mjesto S_P mora imati barem jednu značku dok u mjestu S_{ITER} ne smije biti značka. U početku je samo prijelaz p_1 omogućen jer je tamo jedna značka.

Po aktiviranju prijelaza p_1 jedna će se značka maknuti iz S_0 (u kojem više neće biti značke), jedna značka će se dodati u mjesto S_P, a N znački u S_{ITER}. Aktiviranjem prijelaza p_2 uzeti će se po jedna značka iz S_P i S_{ITER} te potom dodati jedna značka u S_P. Prijelaz p_3 može se aktivirati samo kad u S_P ima bar jedna značka a u S_{ITER} nema niti jedne, zbog inhibicijske veze od S_{ITER} do p_3 (kružić umjesto strelica). Aktiviranjem prijelaza p_3 uzeti će se jedna značka iz S_P te jedna dodati u S_0 – stanje mreže će tada biti jednako početnom, prikazanom na slici 2.8.

Ukratko, prijelaz se aktivira kada su sve ulazne veze zadovoljene, a prijelazom se odgovarajući broj znački miče (troši na prijelaz) iz početnih mjesta i zadani broj znački (zadan na izlaznim vezama) se stavlja u odredišna mjesta. Ako veze (ulazne i izlazne) nemaju oznaku težine, onda se koristi podrazumijevana težina od jedne značke. Prijelaz se može nalaziti samo između mjesta (osim ulaznih prijelaza koji nemaju ulazno mjesto te izlaznih koji nemaju izlazni). Veze (koje su također usmjerene) mogu spajati samo mjesto i prijelaz te prijelaz i mjesto, a nikako mjesto i mjesto ili prijelaz s prijelazom.

Petrijeva mreža na slici 2.8. prikazuje petlju s N iteracija. Prijelaz p_2 može predstavljati akciju u petlji (ili to može biti ulaz u stanje S_P), p_1 (ili ulaz u S_0) akciju koja joj prethodi te p_3 (ili ulaz u S_{ITER}) akciju nakon nje. Slika 2.9. prikazuje simulaciju rada Petrijeve mreže kada je $N = 3$. Oni prijelazi koji su omogućeni u tom stanju, koji će uzrokovati promjenu prikazanu na idućoj

slici, su podebljani.

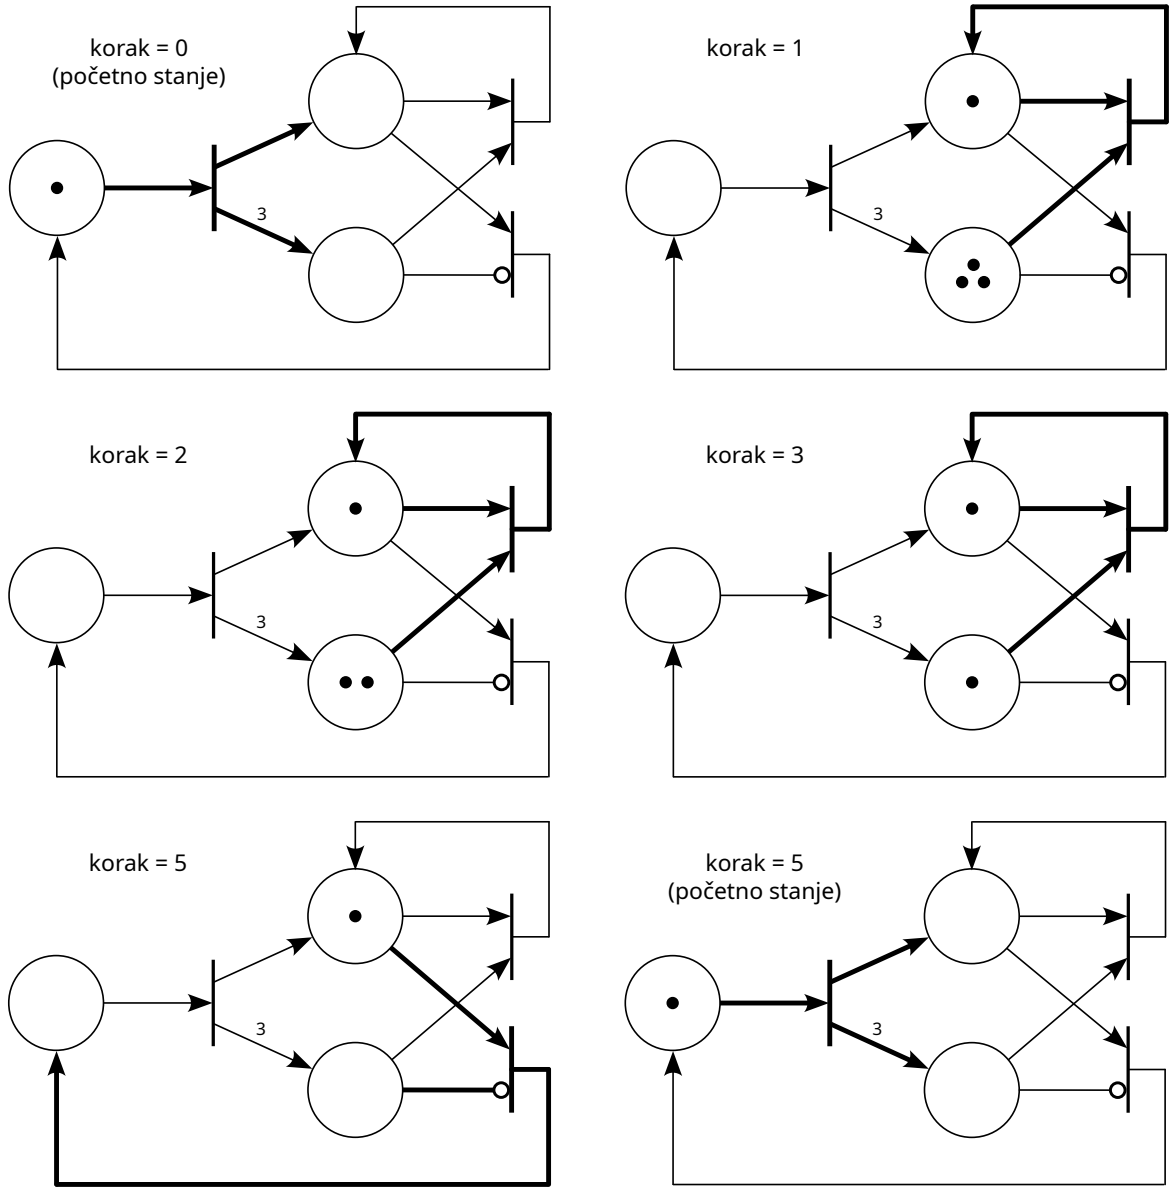

Slika 2.9. Primjer rada Petrijeve mreže

Korištenje Petrijevih mreža prikazano je s još nekoliko primjera.

Primjer 2.2. Skupina poslova

Za skup od N dretvi poznato je da obavljaju isti posao koji se sastoji od dijelova A, B i C (svaka dretva radi A dio, pa B dio, pa C dio te ponovno ispočetka A, B, C, ...). Prva dva dijela, A i B, razne dretve mogu obavljati paralelno, ali dio C moraju obaviti međusobno isključivo (u kritičnom odsječku). Modelirati sustav Petrijevom mrežom, gdje svaka značka u početnom mjestu označava po jednu dretvu.

Rješenje:

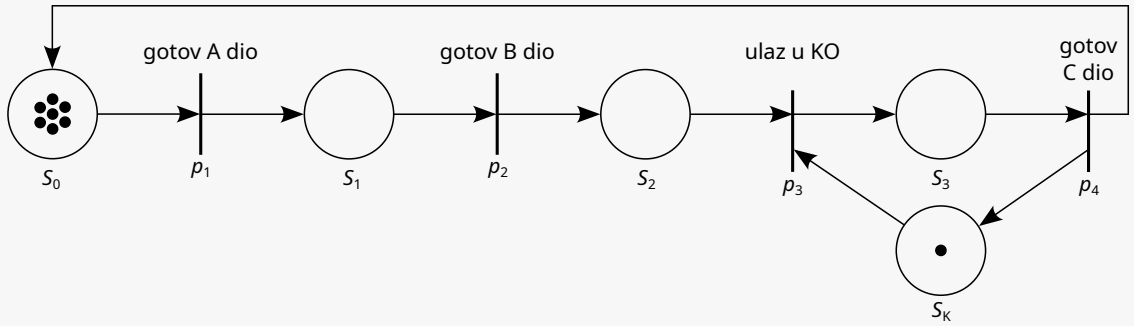

Slika 2.10.

U prikazanom rješenju prijelazi p_1 i p_2 označavaju dovršetak A i B dijelova od strane pojedine dretve. Ti se prijelazi mogu dogoditi u bilo kojem trenutku, pa i u istim trenucima za različite tokene. Kritični odsječak zaštićen je dodatnim stanjem S_K u kojem se početno nalazi jedan token. Aktiviranjem prijelaza p_3 od strane bilo kojeg tokena iz S_2 (koji simulira rad dretve) povlači se i token iz S_K te time onemogućuje prijelaz za iduće tokene iz S_2. Tek pri aktivaciji prijelaza p_4 vraća se token u S_K i prijelaz p_3 se ponovno omogućava.

Primjer 2.3. Proizvođači i potrošač

U sustavu se nalaze ciklički zadaci dva proizvođača i jednog potrošača. Proizvođači stvaraju poruke i stavljaju ih u prazna mjesta međuspremnika (ako je on pun, onda čekaju da se oslobodi jedno mjesto). Potrošač uzima dvije poruke iz međuspremnika te ih procesira. Ako nema bar dvije poruke u međuspremniku onda čeka da se poruke pojave. Modelirati sustav Petrijevom mrežom. Veličina međuspremnika je 7 poruka.

Rješenje:

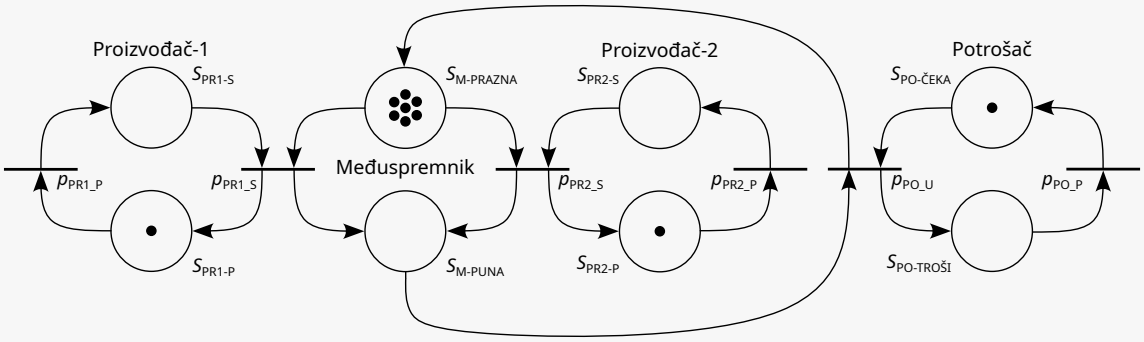

Slika 2.11.

2.2.5. Vremenske Petrijeve mreže

Vremenske Petrijeve mreže omogućuju definiranje vremenskih trenutaka i intervala u kojima se mogu obaviti (aktivirati) neki prijelazi. Ako su definirani, ti intervali su dodatna ograničenja na mrežu, tj. da bi se prijelaz dogodio on mora biti omogućen – ulazne veze moraju imati potreban broj znački u polaznim mjestima.

Primjerice, vremensko ograničenje na prijelaz p_x može se definirati intervalom $[t_1, t_2]$ kao in-

terval u kojem je prijelaz moguće obaviti. Ako se ulazne veze prema prijelazu omoguće prije zadanog intervala, prijelaz se neće obaviti do početka tog intervala. Ako se ulazne veze omoguće nakon intervala, prijelaz se neće dogoditi uopće.

Uobičajeno se kao trenutak mogućeg prijelaza označava trenutak dolaska značke u mjesto S_x i to se označava s $time(S_x)$. To se može iskoristiti za definiranje drukčijeg ograničenja, npr. $[time(S_x), time(S_x) + 2]$ koje definira interval od dvije sekunde od trenutka dolaska tokena u stanje S_x, gdje stanje S_x mora biti jedno stanje s vezom prema prijelazu.

Primjer 2.4. Otvaranje vrata lifta

Modelirati otvaranje i zatvaranje vrata lifta vremenskom Petrijevom mrežom. Neka je već zadana Petrijeva mreža prema slici 2.12.

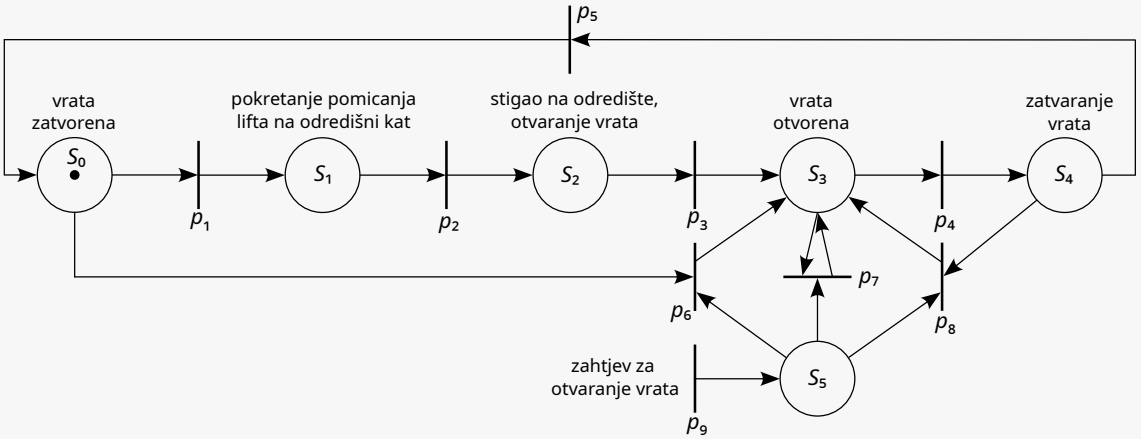

Slika 2.12. Stanja vrata lifta

Uz zadanu mrežu zadana je i specifikacija ponašanja. Početno se lift nalazi na nekom katu sa zatvorenim vratima (stanje S_0). U tom stanju ostaje dok ne dođe zahtjev za pokretanjem lifta, što se ovdje ne modelira. Obzirom da u to stanje dolazi nakon zatvaranja vrata (iz S_4), prije pokretanja u tom stanju treba ostati bar još jednu sekundu. Nakon pokretanja pomicanja lifta on će u nekom budućem trenutku doći na željeni kat te odmah započeti s otvaranjem vrata (stanje S_2). Otvaranje vrata traje točno dvije sekunde. Nakon što su vrata otvorena u tom stanju ostaje pet sekundi i tek onda kreće sa zatvaranjem vrata što sustav ponovno vraća u stanje S_0. Ako zahtjev za otvaranjem vrata stigne dok se ona zatvaraju ili već jesu zatvorena ali lift nije krenuo, vrata treba ponovno otvoriti.

Rješenje:

Za svaki prijelaz treba prema prethodnom opisu provjeriti postoji li dodatno vremensko ograničenje. Ako postoji treba ga definirati. Tablica 2.1. sadrži vremenska ograničenja za sve prijelaze. Vremenska ograničenja su zadana diskretnim trenucima, intervalima ili nisu zadana (–). Vremenska ograničenja za p_6, p_7 i p_8 proističu iz stanja sustava – prijelazi su mogući tek kad značke dođu odgovarajuća ulazna mjesta. Stoga za navedene prijelaze nisu navedena i vremenska ograničenja (navedena su u opisu).

Tablica 2.1. Vremenska ograničenja na prijelaze

prijelaz	ulazna mjesta	vremenska ograničenja	opis (prema tekstu zadatka)
p_1	S_0	$[time(S_0)+1, \infty]$	nakon zatvaranja vrata lift stoji još barem jednu sekundu prije pokretanja
p_2	S_1	–	nije definirano koliko se dugo lift kreće
p_3	S_2	$time(S_0)+2$	potrebne su 2 sekunde za otvaranje vrata
p_4	S_3	$time(S_1)+5$	nakon 5 sekundi započinje se sa zatvaranjem vrata
p_5	S_4	$time(S_2)+2$	potrebne su 2 sekunde za zatvaranje vrata
p_6	S_0, S_5	–	zahtjev za otvaranjem se pojavio dok su vrata bila zatvorena (može se označiti i s $time(S_5)$)
p_7	S_3, S_5	–	ako se zahtjev pojavi dok su vrata otvorena, ponovno se ulazi u stanje S_3 – dodatno vremensko ograničenje nije potrebno (iako se moglo napisati i $time(S_5)$)
p_8	S_4, S_5	–	prekida se zatvaranje i pokreće otvaranje (moglo se napisati i $time(S_5)$)
p_9	–	–	zahtjev za otvaranjem može doći bilo kada

Primjer 2.5. Kritični odsječak

Dva ciklička zadatka P_1 i P_2 u svojem izvođenju prolaze kroz kritični odsječak u kojem koriste zajedničke podatke te potom nastavljaju u nekritičnome. Ulazak u kritični odsječak mora biti zaštićen odgovarajućim sinkronizacijskim mehanizmom tako da u njega uvijek može ući samo jedan zadatak. Trajanje kritičnog odsječka za P_1 je u granicama od 5 do 10 jedinica vremena, a za P_2 u granicama od 10 do 15. Trajanje nekritičnog odsječka za P_1 je u granicama od 5 do 25 jedinica vremena, a za P_2 od 20 do 40. Za zadani sustav izgraditi (grafički prikazati) vremensku Petrijevu mrežu te napisati tablicu s opisom prijelaza.

Rješenje:

Petrijeva mreža prikazana je na slici 2.13., a vremenska ograničenja navedena su u tablici 2.2. Stanja su označena s P_{xU}, P_{xK} te P_{xN} sa značenjima:

- P_{xU} – zadatak x čeka na ulaz u kritični odsječak
- P_{xK} – zadatak x u kritičnom odsječku
- P_{xN} – zadatak x u nekritičnom odsječku

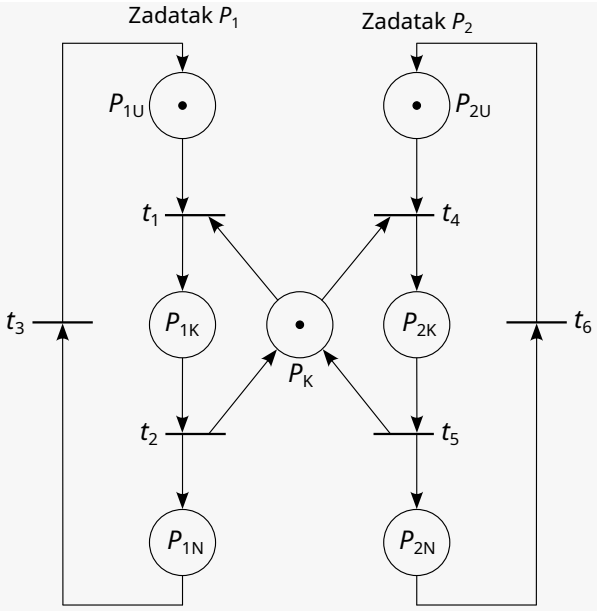

Slika 2.13.
Tablica 2.2. table

prijelaz	ulazna mjesta	vremenska ograničenja
t_1	P_{1U}, P_K	–
t_2	P_{1K}	$[time(P_{1K}) + 5, time(P_{1K}) + 10]$
t_3	P_{1N}	$[time(P_{1N}) + 5, time(P_{1N}) + 25]$
t_4	P_{2U}, P_K	–
t_5	P_{2K}	$[time(P_{2K}) + 10, time(P_{2K}) + 15]$
t_6	P_{2N}	$[time(P_{2N}) + 20, time(P_{2N}) + 40]$

Primjer 2.6. Komunikacija

U nekom komunikacijskom sustavu postoje dvije strane: klijent (K) i poslužitelj (P). Uspostava komunikacijskog kanala obavlja se tako da klijent pošalje zahtjev (REQ) na koji poslužitelj odgovara (ACK). Korištenjem Petrijevih mreža modelirati postupak uspostavljanja kanala. Pretpostaviti da se klijent može naći u stanjima:

- K_0 – prije slanja zahtjeva REQ (početno mjesto)
- K_1 – nakon slanja zahtjeva REQ, čekanje na odgovor
- K_2 – nakon primitka odgovora ACK – veza uspostavljena.

Poslužitelj se može naći u stanjima:

- P_0 – prije primitka zahtjeva REQ (početno mjesto)
- P_1 – nakon primitka zahtjeva REQ, a prije slanja odgovora ACK
- P_2 – nakon slanja odgovora ACK – veza uspostavljena.

Odgovor na klijentov zahtjev ne smije doći prije $T_1 = 10$ μs. U oba slučaja klijent treba ponoviti slanje zahtjeva REQ (vratit se u mjesto K_0).

Rješenje:

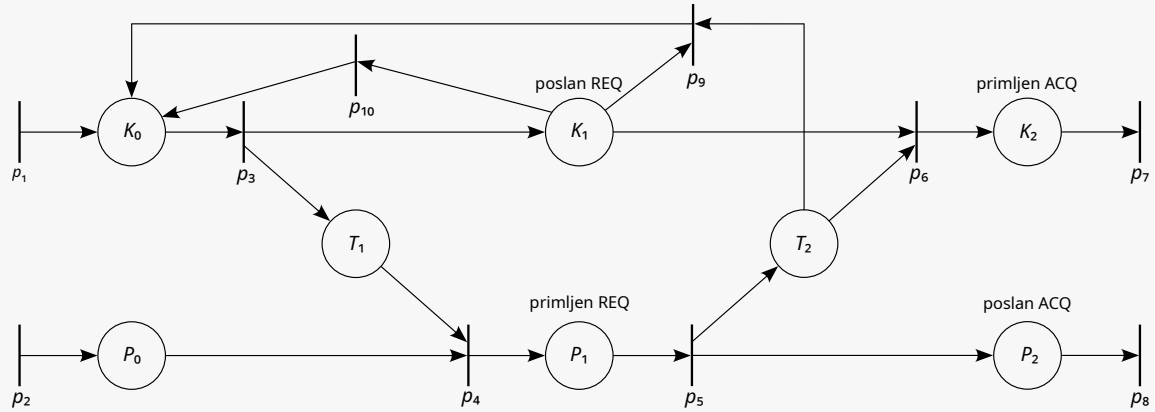

Slika 2.14.

Tablica 2.3.

prijelaz	**ulazna mjesta**	**vremenska ograničenja**
p_1	–	–
p_2	–	–
p_3	K_0	–
p_4	P_0, T_1	–
p_5	P_1	–
p_6	K_1, T_2	$< time(K_1) + T_1, time(K_1) + T_2 >$
p_7	K_2	–
p_8	P_2	–
p_9	K_1, T_2	$[0, time(K_1) + T_1]$
p_{10}	K_1	$time(K_1) + T_2$

Prijelazi $p_1 - p_8$ zbivaju se u očekivanom načinu rada, dok se prijelazi p_9 i p_{10} zbivaju u slučaju grešaka.

Zadavanje ograničenja na p_6 sprječava nedeterminizam (koji je inače dozvoljen) i moguću grešku, obzirom da bi prijelazi p_6 i p_9 mogli biti omogućeni istovremeno u intervalu $[0, time(K_1) + T_1]$, što bi značilo da su oba događaja ispravna (ili p_6 ili p_9) iako to prema tekstu zadatka ne bi trebalo biti. Slično je i s prijelazima p_6 i p_{10} za trenutak $time(K_1) + T_2$.

U ovom rješenju nije modelirano trajanje obrade zahtjeva REQ, tj. nije zadano vremensko ograničenje na prijelaz p_5. Što ako poslužitelj prebrzo ili presporo obradi taj zahtjev? Prema pookazanom rješenju u oba će slučaja poslužitelj pretpostaviti da je sve u redu i da je veza uspostavljena. Ovo je zapravo problem protokola uz navedena vremenska ograničenja samo na jednoj strani. Dodavanjem ograničenja na p_5 sa $< time(P_1) + T_1, time(P_1) + T_2 >$ bi omogućilo ispravan rad te prijelazi p_9 i p_{10} ne bi bili potrebni. Bez toga, poslužitelj će

detektirati da nešto ne valja u ostatku komunikacije (ništa neće dobivati od klijenta), pa će se tada vjerojatno vratiti u početno stanje P_0.

2.3. Primjer upravljačkog programa za lift

Nakon analize sustava te početna modeliranja, npr. UML-dijagramima, može se krenuti u izgradnju. Jedan od prvih koraka je određivanje potrebne strukture podataka za praćenje stanja sustava. Na primjeru lifta to su podaci o svakom liftu: gdje se nalazi, kamo se kreće, stanje vrata; podaci o zahtjevima putnika: pozivi s katova, zahtjevi unutar liftova; stanje signalizacije na katovima i unutar liftova.

Upravljački program treba u petlji pratiti stanje liftova i zahtjeve korisnika te upućivati odgovarajuće liftove u odgovarajuće smjerove. Načelni pseudokod upravljačkog programa prikazan je u 2.1. U pseudokodu se ne koriste zagrade {} za oznaku bloka već se koristi uvlačenje koda, slično kao u programskom jeziku Python.

Isječak kôda 2.1. Osnovna upravljačka petlja za lift

```
upravljački_program ()
  inicijaliziraj sve komponente

  ponavljaj
    dohvati stanje liftova (gdje su, kamo se kreću, ...)
    dohvati zahtjeve s katova i unutar liftova

    dodijeli_zahtjeve_liftovima ()  # funkcija je detaljnije opisana u nastavku

    pošalji naredbe liftovima
    postavi signalizaciju u liftovima i na katovima

    # kada se sustav simulira (simulira se pomak, otvaranje vrata ...)
    obavi korak simulacije nad svakim liftom
    # po potrebi odgodi iduću iteraciju za neko kratko vrijeme

dodijeli_zahtjeve_liftovima ()
  za i = 1 do BROJ_LIFTOVA radi # Zahtjeve iznutra dodijeli odmah
    za j = 1 do BROJ_KATOVA radi
      lift[i].stani[j] |= zahtjev[i][j]

  # Zahtjeve izvana treba dodjeljivati najbližim liftovima. Jedan od algoritama,
  # prikazan u nastavku, pretražuje neobrađene zahtjeve dok ne pronađe onaj koji
  # je najbliže nekom liftu. Nakon dodjele tog zahtjeva, traži se idući "najbliži"
  # te tako dok se svi ne "obrade".

  z = kopija (poziv) # radna kopija aktivnih zahtjeva
  # z[x][y] - zahtjev s kata x za smjer y (y iz {1,2})

  dok z nije prazan radi
    min_kat = min_smjer = min_lift = 0
    min_udaljenost = BROJ_KATOVA + 1

    za j = 1 do BROJ_KATOVA radi # iteracija po katovima
      za k = 1 do 2 radi         # iteracija po smjerovima
        ako je z[j][k] != 0 tada
          za i = 1 do BROJ_LIFTOVA radi
            # Izračunati udaljenost lifta za ovaj zahtjev. Uzeti u obzir i smjer
            # gibanja lifta, ide li lift i na katove nakon poziva, ako je poziv
            # za suprotni smjer i slično.
            udaljenost = izračunata udaljenost
```

```
            ako je udaljenost < min_udaljenost tada
              min_udaljenost = udaljenost;
              min_kat = j;
              min_smjer = k;
              min_lift = i;

    ako je min_udaljenost < BROJ_KATOVA + 1 tada
      # Dodijeliti zahtjev najbližem liftu.
      lift[min_lift].stani[min_kat] = 1;
      lift[min_lift].poziv[min_kat][min_smjer] = 1;
      # Dodatno: postaviti smjer, ako je potrebno. Provjeriti je li navedeni
      # zahtjev već bio prije dodijeljen nekom drugom liftu. Ako jest, onda ga
      # maknuti od tamo i po potrebi maknuti to stajanje onom liftu, ali i dodati
      # neko stajanje tom liftu ako se giba, a više nema stajanja.

    # Označiti zahtjev kao "obrađen" (neovisno o tome je li dodijeljen).
    z[min_kat][min_smjer] = 0;
```

Navedeni pseudokod upravljačke petlje je vrlo općenit, ne uključuje module za komunikaciju ili simulator, ali svejedno može biti početna točka za izgradnju upravljačkog programa.

2.4. Proces izgradnje programske potpore

Izgradnja složenih sustava je složen proces. Programska komponenta SRSV-a (programska potpora, engl. *software*) često je vrlo složena te pri njenoj izgradnji treba primjenjivati postupke koji će moći tu složenost nadvladati. Osnovni način rješavanja složenosti je "podijeli i vladaj" te se i postupak izgradnje sustava treba posmatrati kao proces nad kojim se može primijeniti isto načelo.

U nastavku su kratko navedene uobičajene metodologije koje se koriste u procesu izgradnje sustava. Za detaljniji prikaz pojedine od metodologija može se koristiti literatura iz područja programskog inženjerstva (engl. *software engineering*) gdje se to detaljno opisuje.

Proces izgradnje programske potpore može se podijeliti u nekoliko osnovnih aktivnosti:

1. izrada specifikacije (engl. *requirements*)
2. oblikovanje arhitekture (engl. *design*)
3. izrada komponenata – programiranje (engl. *implementation*)
4. ispitivanje ispravnosti – testiranje
5. održavanje – ugradnja, nadogradnja, evolucija (engl. *maintenance*).

Izrada *specifikacije* uključuje analizu zahtjeva, provedbu studije izvedivosti, izlučivanje zahtjeva te izradu dokumenta specifikacije koji je podloga ugovora za projekt, ali i za cijeli proces razvoja, počevši s oblikovanjem arhitekture.

Oblikovanje arhitekture je vrlo bitna aktivnost, većinom najbitnija, jer određuje "kako" sustav treba napraviti te je glavni nositelj konačne kvalitete produkta. Uobičajeno su arhitekture zasnovane na događajima, protoku podataka, objektima, komponentama, slojevima, repozitoriju podataka i klijent-poslužitelj organizaciji.

Izrada komponenata uključuje programiranje (izgradnju) sustava. Izgradnja treba slijediti arhitekturu te zahtjeve specifikacije.

Ispitivanje kao aktivnost ne bi trebala biti zasebna aktivnost u procesu izgradnje programa već uključena u sve aktivnosti, od izrade specifikacije, oblikovanja arhitekture, programiranje kom-

ponenti i njihovoj integraciji do ispitivanje ispravnosti ugrađenog sustava. Osnovni problem ispitivanja složenih sustava jest u tome što se oni ne mogu u potpunosti ispitati – ima previše mogućih stanja sustava. Zato bi ispitivanje trebalo uključiti u sve aktivnosti i komponente sustava koje su znatno manje složenosti od gotovog sustava.

Nakon dovršetka izrade sustava i njegove ugradnje započinje *proces održavanja* koji uključuje naknadne izmjene kao što su ispravke, prilagodbe i nadogradnje. Za sustave s predviđenim dugim životnim vijekom moguće je da održavanje bude višestruko skuplje od samog procesa izgradnje te i to treba uzeti u obzir pri razmatranju ostvarenja sustava.

Navedene opće aktivnosti procesa izgradnje programske potpore ne moraju se izvoditi kao koraci, najprije prva pa druga itd. Postoje razni modeli procesa izgradnje koji su primjenjivi u raznim situacijama, kao što su vodopadni, evolucijski, iterativni, inkrementalni i komponentno oblikovanje.

Vodopadni model zahtjeva da svaka aktivnost bude gotova prije nego li se krene sa sljedećom. On je zato primjenjiv u velikim razvojnim timovima, gdje pojedine aktivnosti obavljaju različite osobe i timovi te je bitno da pojedina aktivnost bude gotova prije nego li se krene s idućom.

Evolucijski modeli primjenjivi su na sustave kod kojih specifikaciju nije jednostavno napraviti te se započinje s jednim rješenjem koje se popravlja i nadograđuje da zadovolji naknadno uočene zahtjeve i nedostatke. Zbog početno odabranog rješenja bez dublje analize te naknadnih dodataka, arhitektura tako nastalih sustava može biti vrlo loša. Međutim, ako se radi o sustavima napravljenim samo za neki događaj onda se ovim modelom vrlo brzo može doći do rješenja te problem održavanja, koji bi bio skup s obzirom na lošu arhitekturu, neće biti prisutan.

Iterativni modeli koriste iteracije radi popravljanja i unapređenja pojedinih elemenata sustava, od specifikacije, arhitekture, oblikovanja komponente do testiranja. Zapravo bi mogli reći da svi modeli uključuju iterativni pristup, barem lokalno, nad pojedinom komponentom. Ovisno o dozvoljenom vremenu za razvoj broj iteracija se prilagođava (povećava ili smanjuje), svakom iteracijom poboljšavajući pojedini segment u razvoju.

Kod *inkrementalnog pristupa* sustav se izrađuje u inkrementima. Prvi inkrement koji se isporučuje naručitelju sadrži osnovnu funkcionalnost, dok idući inkrementi dodaju ostale funkcionalnosti. Prednost inkrementalnog pristupa je u ranoj isporuci proizvoda, manji rizik za neuspjeh projekta te mogućnosti većeg ispitivanja osnovnih funkcija koje su ostvarene u startu, a ispituju se i u radu.

Oblikovanje zasnovano na *komponentnom pristupu* kreće od pretpostavke da se u rješavanju problema uključe već gotove komponente, a da se što je moguće manje izgrađuju nove. Prednosti ovog pristupa su u vrlo kratkom vremenu izgradnje sustava s obzirom na to da se većina komponenata ne treba izgraditi već samo spojiti već postojeće. Nadalje, gotove su komponente već opsežnije ispitane i samom uporabom u drugim sustavima te se ovim pristupom može povećati pouzdanost sustava.

U praksi se često kombiniraju elementi više modela.

2.5. Posebnosti izgradnje SRSV-a

Oblikovanje SRSV-a može se obaviti bilo kojim metodologijom, prema procjeni arhitekta, kao i pri izradi drugih sustava. Međutim, zbog potrebe zadovoljenja vremenskih ograničenja, u svakom postupku treba birati prikladne metode i komponente i postupke koji će ih moći zadovoljiti. Primjerice, potrebno je odabrati prikladan programski jezik i alate, potrebno je sprovesti analizu složenosti algoritama i kôda, analizirati sklopovlje i slično. Možda najveća razlika u od-

nosu na ostale sustave je u postupku ispitivanja koje je za SRSV-e daleko opsežnije i temeljitije.

Proces izgradnje se ne sastoji samo od programiranja. Ako programiranje započne prije nego li se sustav temeljitije analizira i dokumentira, izrada programa je znatno teža i sklonija pogreškama, rezultirajući produktom loše arhitekture kojeg je teže ispitati i održavati. Zato se niz početnih aktivnosti u izradi SRSV-a ne smije olako shvatiti i površno obaviti. Grafičke metode, poput skice i UML-dijagrama te Petrijevih mreža, mogu znatno olakšati proces savladavanja problema, njegove analize i pronalaska rješenja.

2.5.1. Formalna verifikacija

Možda najveća razlika u procesu ostvarenja programske komponente za SRSV-e jest u ispitivanju ispravnosti rada. Ispitivanja SRSV-a moraju biti značajno temeljitija. U tom smjeru su i preporuke znanstvenih i stručnih organizacija (npr. IEEE) da se ispitivanje ne izvodi samo primjenom ispitivanja korištenjem ulaznih podataka i očekivanih rezultata, već da se koristi *formalna verifikacija*. Naime, zbog praktički beskonačno velike domene (mogućih ulaza i stanja sustava) sama ispitivanja zbog vremenskih ograničenja mogu ispitati samo dio te domene, tj. ispitati rad sustava samo u jednom malom dijelu domene. Kad bi se ispravno provela, formalna verifikacija bi korištenjem formalnih postupaka mogla provjeriti ispravnost sustava u cijeloj domeni.

Problem formalne verifikacije jest u njenoj primjeni. Specifikaciju zahtjeva prema sustavu treba pripremiti u formalnom obliku. Izgrađeni sustav treba formalno opisati. Ako formalna specifikacija zahtjeva te formalni model implementacije ne odgovaraju u potpunosti stvarnim specifikacijama i implementaciji, rezultati formalne verifikacije neće biti vjerodostojni.

Za pripremu formalne specifikacije te formalnog modela za implementaciju kao i za provedbu postupaka formalne verifikacije potrebna su značajna znanja iz područja formalnih postupaka koju rijetki današnji inženjeri posjeduju.

Područje formalnih postupaka je suviše opsežno i složeno te nije ovdje prikazano.

Pitanja za vježbu 2

1. Navesti svojstva skice i tekstovnog opisa kao metoda u postupku projektiranja sustava.
2. Zašto nije dobro izradu programske potpore započeti bez pripreme (npr. korištenjem skice sustava, dijagrama stanja i slično)?
3. Navesti osnovne razloge korištenja UML dijagrama obrazaca uporabe, sekvencijskih, komunikacijskih i dijagrama stanja.
4. S kojim UML dijagramom se najbolje prikazuje tijek odvijanja neke operacije s pripadnim porukama, pozivima funkcija komponenata i slično, gdje je bitno uočiti vremenski redoslijed?
5. Kada se koriste neformalni postupci, a kada formalni (u kontekstu izgradnje SRSV-a)?
6. Navesti elemente Petrijeve mreže i njihova svojstva.
7. Opisati razliku između vremenskih Petrijevih mreža i običnih Petrijevih mreža. Koje nove mogućnosti nude vremenske mreže?

8. Opisati uobičajene aktivnosti u procesu izgradnje programske potpore.
9. Koje su prednosti korištenja procesa izgradnje programske potpore (bilo kojeg modela, sa svim aktivnostima procesa) naspram postupka koji ide bez toga, tj. kod kojeg se odmah kreće s programiranjem?
10. Ukratko opisati svojstva osnovnih modela procesa izgradnje.
11. Navesti aktivnosti procesa izgradnje programske potpore i redoslijed njihova izvođenja u vodopadnom modelu.
12. Navesti aktivnosti procesa izgradnje programske potpore i UML dijagrame koji se koriste u njima te za što se pojedini dijagram koristi u pojedinoj aktivnosti.
13. U nekom sustavu pri obradi jednog zahtjeva sudjeluje pet dretvi: ulazna koja zaprima zahtjev, tri radne koje paralelno rade na tom istom zahtjevu te izlazna koja radi završnu obradu tek kad su radne dretve gotove i vraća rezultat. Prikazati navedeni sustav Petrijevom mrežom.
14. Sustav s jednim liftom i dva stajanja, prizemlje i prvi kat, ima sljedeća svojstva: otvaranje vrata kao i zatvaranje traje 2 sekunde, vrata su otvorena minimalno 5 sekundi, pomak lifta na prvi kat, kao i obratno traje 10 sekundi. Pretpostaviti da se koriste samo vanjske tipke za poziva lifta – bez unutarnjih tipki, tj. kada se lift pozove, on dođe, otvori vrata, zatvori vrata i ode na onu drugu poziciju te otvori vrata. Prikazati lift vremenskim Petrijevim mrežama uzimajući u obzir zahtjeve, tj. pozive liftu.
15. Vremenskom Petrijevom mrežom modelirati ulazak kupaca u trgovinu, tj. automatsko otvaranje vrata pred kupcem. Pretpostaviti da se pred pokretnim vratima nalazi senzor koji će detektirati potencijalnog kupca i poslati signal prema upravljačkom računalu koje tada pokreće otvaranje vrata. Otvaranje i zatvaranje traju po dvije sekunde, a minimalno vrijeme s otvorenim vratima jest pet sekundi. Ako senzor i dalje šalje signale o detekciji kupca vrata trebaju biti otvorena za idućih pet sekundi, tj. započet će se sa zatvaranjem najranije pet sekundi nakon zadnjeg signala. Ako se u postupku zatvaranja detektira novi kupac, potrebno je prekinuti zatvaranje i ponovno otvoriti vrata.
16. Neka automatska praonica upravljana je računalom. Sustav se sastoji od tri trake: prve ispred ulaza u praonicu, druge koja vodi auto kroz praonicu do izlaza te treća na izlazu. Vozač se doveze na prvu traku i ugasi auto. Kad auto trenutno u praonici izađe, pokrenu se prva i druga traka, dok novi auto ne uđe u praonicu. Potom počinje pranje. Po dovršetku pranja, ako je prethodno oprani auto na izlaznoj traci otišao, aktiviraju se druga i treća traka i odvezu auto van. Trake su opremljene senzorima težine. Opisati sustav Petrijevom mrežom te UML dijagramom stanja.
17. Lift u nekoj zgradi ima dvije brzine kretanja: normalnu, kada prevozi putnike te brzu kada je prazan. Pri pokretanju lifta, on se naprije ubrzava na potrebnu brzinu kretanja te potom nastavlja konstantnom brzinom skoro do odredišna kata, kada započinje sa smanjivanjem brzine do zaustavljanja. Po zaustavljanju započinje s otvaranjem vrata, pa neko vrijeme stoji s otvorenim vratima te ih konačno zatvara. Ako nema novih zahtjeva lift stoji. Za opisani lift napraviti UML dijagram stanja.

3. Ostvarenje upravljanja

Zadaća računala u SRSV-ima je nadzor i upravljanje. Za programsko ostvarenje upravljanja treba analizirati problem i odabrati odgovarajući način upravljanja što uključuje odabir prikladne strukture programa, odabir prikladnih upravljačkih algoritama i njihovih parametara. U ovom poglavlju razmatraju se mogući načini upravljanja s obzirom na strukturu kôda i način pokretanja pojedinih aktivnosti. U drugom dijelu poglavlja ukratko se prikazuju osnovni načini ostvarenja automatskog upravljanja sustavom korištenjem PID regulatora te korištenjem neizrazite logike.

3.1. Struktura programa za upravljanje SRSV-ima

Upravljanje nekim sustavom podrazumijeva upravljanje njegovim komponentama. Upravljanje jednom komponentom se najčešće sastoji od očitavanja stanja sustava, proračuna što slijedeće napraviti (ako je potrebno) te slanje naredbi aktuatoru, kao što je ilustrirano na slici 3.1.

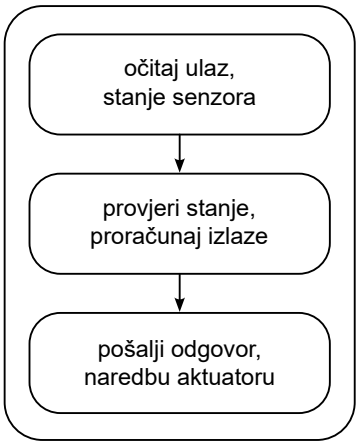

Slika 3.1. Upravljanje jednom komponentom sustava

Upravljanje SRSV-ima može se ostvariti na razne načine, ovisno o potrebama i složenosti sustava. Strukture programa koje se mogu koristiti za ostvarenje upravljanja mogu se svrstati u nekoliko osnovnih kategorija:

- programska petlja, tj. upravljačka petlja
- upravljanje zasnovano na događajima (prekidima)
- korištenje jednostavne jezgre operacijskog sustava (s prekidima i alarmima)
- kooperativna višedretvenost (programski ostvarena višedretvenost)
- višedretvenost (raspoređivanje, sinkronizacija, komunikacija; korištenje OS-a za SRSV)
- raspodijeljeni sustavi (komunikacija, usklađivanje među čvorovima).

Složeniji načini nude više mogućnosti, ali i zahtjevaju primjenu složenijih postupaka i složenijeg sklopovlja (skuplji su). U ovom poglavlju razmotrene su mogućnosti navedenih načina upravljanja te su prikazane ideje za njihovo korištenje.

3.1.1. Upravljačka petlja

Za najjednostavnije ugrađene sustave dovoljno je koristiti i najjednostavnije sklopovlje – mikroupravljač (engl. *microcontroller*) koji upravlja sustavom cijelo vrijeme izvodeći jednu *programsku petlju*. U toj se petlji očitavaju ulazni podaci, npr. preko senzora, proračunavaju se potrebne akcije, koje se potom pokreću u definiranim trenucima. Slika 3.2. ilustrira rad upravljačke petlje u kojoj se slijedno upravlja s više komponenti sustava.

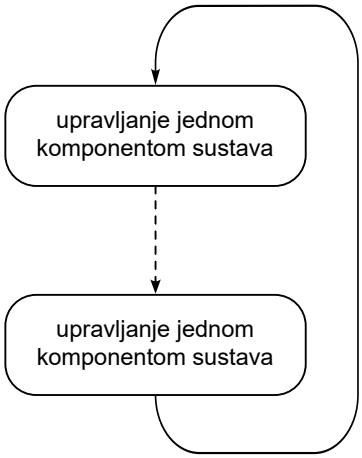

Slika 3.2. Upravljačka petlja

Opće ponašanje moglo bi se prikazati i pseudokôdom, primjerice kao u 3.1.

Isječak kôda 3.1. Upravljačka petlja

```
upravljanje()
  inicijalizacija()
  ponavljaj
    s1 = očitaj_senzor_1()
    ako je potrebna_akcija_1(s1) tada
      pokreni_akciju_1(s1)
    s2 = ... # slično za ostale elemente
```

Ako je za upravljanje potrebno vrijeme ili treba ostvariti odgođene (periodičke) poslove tada se navedeni kôd može proširiti prema 3.2.

Isječak kôda 3.2. Upravljačka petlja uz korištenje vremena

```
upravljanje()
  inicijalizacija()
  ponavljaj
    s1 = očitaj_senzor_1()
    t = ažuriraj_vrijeme()
    ako je potrebna_akcija_1(s1, t) tada
      pokreni_akciju_1(s1, t)
    s2 = ...

    ako je ima_odgođenih_poslova(t) tada
      pokreni_odgođene_poslove(t)
```

Navedena struktura može biti dovoljna za mnoštvo sustava, npr. za alarmne sustave i jednostavnije podsustave upravljanja. Složeniji sustavi se također mogu ostvariti na ovaj način, ali će tada izvedba biti složenija. Slijedi nekoliko ideja za ostvarenje upravljanja korištenjem petlje.

Primjer 3.1. Alarmni sustav

U nekom sustavu zadatak upravljačkog programa jest da periodički provjerava senzore te da pri detekciji odstupanja očitane vrijednosti aktivira alarm.

Sljedeće rješenje prikazuje jednu mogućnost ostvarenja gdje se u petlji provjeravaju senzori te u slučaju vrijednosti izvan granica aktivira alarm.

```
upravljanje()
  ponavljaj
    t1 = ažuriraj_vrijeme()
    za i = 1 do N radi
      s[i] = očitaj_senzor(i)
      zapiši_očitanje(i, s[i])
      ako je s[i] < S[i].min ili s[i] > S[i].max tada
        aktiviraj_alarm(i)
    ponavljaj
      t2 = ažuriraj_vrijeme()
    dok je t2 < t1 + period_provjere
```

U idućim primjerima pretpostavljeno je da se stanje elemenata sustava može kontinuirano učitavati te naredbe slati u bilo kojem trenutku, bilo kojom učestalošću. Ako to ne bi bilo tako, u kôd bi trebalo dodati dodatne provjere ili odgode.

Primjer 3.2. Ručno upravljana robotska ruka

U nekom sustavu zadatak upravljačkog programa je da stanje upravljačke palice prenese u naredbe aktuatorima. Upravljački program treba preko senzora dohvatiti stanje upravljačke palice, proračunati željeno stanje aktuatora te poslati naredbe koje će pomicati sustav prema tom stanju.

```
upravljanje()
  ponavljaj
    smjer = očitaj_položaj_upravljačke_palice()
    pomak = izračunaj_potreban_pomak(stanje, smjer)
    pošalji_naredbe_aktuatorima(pomak)
```

Složenost očitanja senzora i potrebne pretvorbe vrijednosti, kao i izračuna te slanje naredaba je u prikazanome rješenju prebačena u funkcije.

Primjer 3.3. Upravljanje kočenjem

U nekom sustavu zadatak upravljačkog programa je da pri detekciji proklizavanja auta nasumičnim brzim otpuštanjem i aktiviranjem kočnice smanji ukupni put kočenja (smanji proklizavanje). Idejno rješenje u nastavku prvo provjerava je li kočenje uključeno. Ako jest, onda na osnovu brzina okretanja kotača i stanja pedale za kočenje provjerava je li došlo do proklizavanja. Ako ima proklizavanja, potrebno je proračunati prilagođeno upravljanje kočnicama (koji kotač kočiti, koji privremeno otpustiti). Algoritam proračuna ovisi o mnogo parametara i nije razmatran u ovom primjeru.

```
upravljanje()
```

```
  ponavljaj
    kočenje = dohvati_stanje_pedale_kočnice()
    ako je kočenje > 0 tada
      b = očitaj_brzine_svih_kotača()
      ako je provjeri_proklizavanje(kočenje, stanje, b) tada
        t = ažuriraj_vrijeme()
        stanje = proračunaj_novo_stanje(kočenje, stanje, b, t)
        za i = 1 do 4 radi
          postavi_stanje_kočnice_za_kotač(stanje, i)
      inače
        postavi_kočnice(kočenje)
    inače
      postavi_kočnice(0)
```

U sustavima kod kojih upravljanje elementima treba izvoditi periodički, gdje svaki element ima različitu periodu potrebno je ažurnije pratiti protok vremena. Sljedeći primjeri prikazuju neke mogućnosti, svaki sa svojim prednostima i nedostacima.

Primjer 3.4. Periodičko očitanje senzora (1)

U nekom sustavu zadatak upravljačkog programa jest periodički očitavati senzore s_1, s_2, s_3 i s_4 s periodama 30 ms, 40 ms, 20 ms te 100 ms, respektivno. Jedno rješenje slijedi.

```
N = 4
T[N] = { 30, 40, 20, 100 } # periode (konstante)
t[N] = { 30, 40, 20, 100 } # koliko do iduće aktivacije

upravljanje()
  ponavljaj
    t1 = ažuriraj_vrijeme()
    odgodi = t[1]
    za i = 2 do N radi
      ako je t[i] < odgodi tada
        odgodi = t[i]

    ponavljaj
      t2 = ažuriraj_vrijeme()
    dok je t2 < t1 + odgodi

    za i = 1 do N radi
      t[i] -= odgodi
      ako je t[i] <= 0 tada
        s = očitaj_senzor(i)
        poduzmi_akcije(i, s)
        t[i] += T[i]
```

Alternativno rješenje za ostvarenje periodičkih poslova moglo bi uzeti najmanji korak kojim bi se sigurno zaustavili u svakom potrebnom trenutku. Za prethodni primjer taj korak iznosi 10 ms, tj. svaka bi odgoda trajala 10 ms nakon koje bi išlo ažuriranje vremena do idućih očitanja senzora (`t[i] -= 10 ms`) te eventualno i pokretanje očitanja ako je vrijeme dostignuto (`t[i] <= 0`).

Pristup iz prethodna primjera će biti dovoljno precizan jedino ako sve operacije vrlo kratko traju, pogotovo `očitaj_senzor` i `poduzmi_akcije`. Kada bi neka operacija trajala duže, vrijeme odgode bi se povećavalo, ali ne i uračunalo pri određivanju sljedećih izvođenja. U

tim slučajevima bolje je koristiti apsolutno vrijeme za aktivaciju te uspoređivati ga s trenutnim vremenom. Idući primjer koristi navedeni pristup.

Primjer 3.5. Periodičko očitanje senzora (2)

Korištenjem apsolutnog vremena pri određivanju vremena za periodičku aktivacije operacija za isti zadatak iz prethodnog primjera postiže se znatno veća preciznost neovisna o trajanju pokretanja akcija.

```
N = 4
T[N] = { 30, 40, 20, 100 } # periode (konstante)
t[N] # kada je iduća aktivacija

upravljanje()
  # postavi početna vremena ažuriranja
  t = ažuriraj_vrijeme()
  za i = 1 do N radi
    t[i] = t + T[i]
                                        #
  ponavljaj                             # ili pojednostavljeno:
    t = ažuriraj_vrijeme()              #  t = ažuriraj_vrijeme()
    odgodi_do = t[1]                    #  x = 1
    za i = 2 do N radi                  #  za i = 2 do N radi
      ako je odgodi_do > t[i] tada      #    ako je t[x] > t[i] tada
        odgodi_do = t[i]                #       x = i
                                        #
    ponavljaj                           #  ponavljaj
      t = ažuriraj_vrijeme()            #    t = ažuriraj_vrijeme()
    dok je t < odgodi_do                #  dok je t < t[x]
                                        #
    za i = 1 do N radi                  #  s = očitaj_senzor(x)
      t = ažuriraj_vrijeme()            #  poduzmi_akcije(x, s)
      ako je t[i] <= t tada             #  t[x] += T[x]
        s = očitaj_senzor(i)            #
        poduzmi_akcije(i, s)
        t[i] += T[i]
```

U prethodna dva primjera 3.4. i 3.5. relativno jednostavni zahtjevi (periodičke akcije) zahtjevaju ne tako jednostavno rješenje kada se koristi upravljačka petlja. Kada sustav kojeg treba upravljati sadrži više od jednog elementa čije očitanje ili upravljanje nije sinkronizirano, ostvarenje upravljanja s petljom postaje sve složenije i teže za osmisliti i ostvariti. Povećana složenost vodi i do povećane mogućnosti grešaka i njihova težeg otkrivanja. Ipak, ponekad je i složenije sustave moguće upravljati programskom petljom ako se odabere prikladna struktura podataka za zapis stanja svih elemenata sustava.

Primjer 3.6. Upravljanje sustavom s više elemenata

Pretpostavimo poopćeni sustav s više elemenata, kod kojih svaki od elemenata može biti u nekom stanju te drukčije reagira na događaje ovisno o stanju u kojem se trenutna nalazi. Neka se stanje elementa zapisuje u odgovarajuću podatkovnu strukturu. Nadalje, pretpostavimo da su akcije koje poduzima upravljačko računalo kratkog trajanja. Npr. akcije su tipa “pročitaj senzor”, “proračunaj potrebnu akciju” te “pošalji naredbu”. Upravljanje takvim sustavom korištenjem petlje moglo bi izgledati:

```
stanje[N] # stanje za svaki element

upravljanje()
  ponavljaj
    za i = 1 do N radi
      ulazi = očitaj_stanje_i_ulaze_za_element(i)
      t = ažuriraj_vrijeme()
      proračunaj_i_poduzmi_potrebne_akcije(i, stanje[i], ulazi, t)

proračunaj_i_poduzmi_potrebne_akcije(i, stanje, ulazi, t)
  kada je stanje:
    STANJE_1:
      ... //naredbe za upravljanje kad je komponenta u ovom stanju
    STANJE_2:
      ...
```

Kada očitanja, proračuni ili pokretanje akcija ne bi bili kratki, reakcija na neke događaje određene komponente (koji se u ovom načinu otkrivaju očitanjem senzora) bi mogla biti neprihvatljivo duga, a sve zbog čekanja na dovršetka obrade prijašnjih komponenata u lancu. Za rješenje ovakvih problema ipak bi trebalo koristiti složenije sustave (prekide, višedretvenost).

3.1.2. Upravljanje zasnovano na događajima (prekidima)

Za mnoge sustave upravljanje zapravo predstavlja reakciju na događaje iz okoline. U prethodnom načinu upravljanja smo takve događaje otkrivali periodičkim očitavanjem senzora. Međutim, ako je neophodna vrlo brza reakcija tada treba ili velikom frekvencijom očitavati senzore ili koristiti druge mehanizme koji će u *trenutku događaja* i reagirati, bez odgađanja. U računalnom sustavu postoji *mehanizam prekida* i njegove obrade koji mogu poslužiti upravo za ostvarenje ovakvog načina upravljanja. Takvi sustavi moraju imati "podsustav za prihvat prekida" koji će omogućiti povezivanje događaja koji uzrokuje prekid i akciju koju treba poduzeti (funkciju za obradu prekida).

Prekidni podsustav mora pružati sučelje za povezivanje događaja s funkcijom koja ga obrađuje. Pri inicijalizaciji sustava prekidi se povežu s odgovarajućim funkcijama za obradu (upravljačkim programima naprava, engl. *device drivers*). Dok nema događaja procesor može raditi nešto drugo, npr. upravljati elementima sustava koji se ne javljaju mehanizmom prekida. Stoga se upravljanje korištenjem prekida može smatrati i nadogradnja upravljanja petljom. Cijena nadogradnje je dodatno potrebno sklopovlje za prihvat prekida (npr. složeniji procesori) te programski podsustav za upravljanje prekidima.

Prema potrebi (i mogućnostima) svakom se izvoru prekida može pridijeliti *prioritet* kojim se u slučaju višestrukih prekida ili u slučaju pojave jednog prekida za vrijeme obrade drugog može odlučiti koji će se prije obraditi. Pri preklapanju prekida, odabire se onaj prekid većeg prioriteta, dok se obrada prekida manjeg prioriteta blokira ili privremeno prekida dok se prioritetniji ne obradi. Kontekst prijašnjeg posla, tj. nekog programa ili obrade prekid manjeg prioriteta se pri prihvatu prekida privremeno pohranjuje na stog s kojeg se i obnavlja po završetku obrade.

U pojedinim dijelovima programa ili obrade prekida može biti potrebno privremeno zabraniti prekidanje. Npr. ako se u nekom segmentu kôda koriste zajedničke strukture podataka (npr. prekidnog podsustava) taj bi se segment trebao zaštititi tako da se započeta operacija obavi do kraja, da struktura podataka ostane u konzistentnom stanju. Prekidni podsustav mora omogućiti mehanizam *zabrane* te ponovne *dozvole prekidanja*.

Dakle, u sustavima koji posjeduju prekidni podsustav upravljanje nekim elementima se može

ugraditi u funkcije obrade prekida. Opća slika rada sustava upravljanog prekidima, tj. *pojavom događaja*, sastoji se od niza funkcija koje se pozivaju iz prekida. Upravljanje može biti ostvareno isključivo u prekidnim funkcijama ili se za upravljanje mogu koristiti i drugi principi kao što je petlja. Česta je kombinacija petlje i obrade prekida, kao u primjeru 3.3.

Isječak kôda 3.3. Upravljanje koje kombinira prekide s drugim oblicima

```
inicijalizacija()
  postavi_prekidni_podsustav()
  poveži_prekide_s_odgovarajućim_funkcijama()
  pokreni_upravljanje() # npr. petljom

obrada_prekida_1()
  prekidni_dio_upravljanja_napravom_1()

obrada_prekida_2()
  prekidni_dio_upravljanja_napravom_2()

obrada_prekida_3()
  prekidni_dio_upravljanja_napravom_3()
...
```

Prekidni podsustav je začetak jezgre operacijskog sustava. Dodavanje novih podsustava proširuje mogućnosti upravljanja, ali i zahtjeva početno složeniji sustav, sa svojim dodatnim zahtjevima na sklopovlje (procesor, spremnik) i programe (programski i podatkovni dio podsustava).

3.1.3. Jednostavna jezgra operacijskog sustava

Nadogradnjom prekidnog podsustava s *podsustavom za upravljanje vremenom*, tj. mogućnošću odgode i postavljanja *alarma* koji se aktiviraju u budućim trenucima, dobiva se *jednostavna jezgra operacijskog sustava*. Za navedene operacije potrebno je brojilo koje sinkrono odbrojava i izaziva prekid po svom dovršetku (dolasku do nule). U obradi prekida brojila pregledava se vrijednost odgode te aktivni alarmi. Ako je odgoda istekla, program nastavlja s radom. Ako je neki alarm istekao, njega se sada aktivira (pozove funkcija zadana pri stvaranju alarma). Slika 3.3. ilustrira upravljanje sustavom s jednostavnom jezgrom.

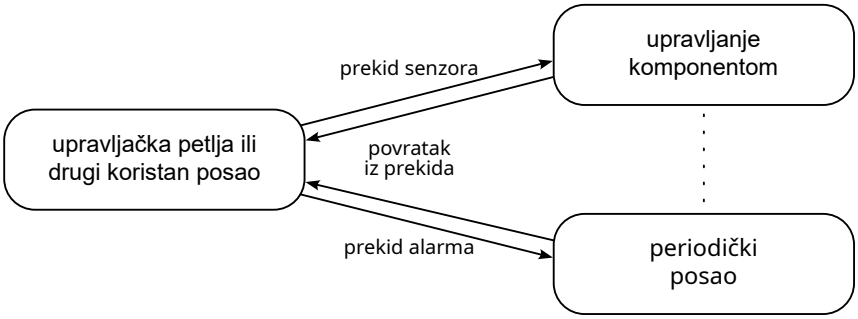

Slika 3.3. Prekidi i alarmi kao jednostavna jezgra operacijskog sustava

Osnovna sučelja podsustava za upravljanje vremenom uključuje nekoliko operacija:

- dohvat trenutnog vremena – `dohvati_vrijeme()`
- relativna odgoda – `odgodi(koliko)` (`sleep()`)
- odgoda do određenog budućeg vremena – `odgodi_do(do_kada)` (`sleep_until()`)
- stvaranje alarma – `postavi_alarm(prva_aktivacija, period, akcija)`

- `prva_aktivacija` relativna odgoda do prve aktivacije alarma
- `period`, ako je zadan (nije nula), definira periodičke alarme, koji će se aktivirati svakih `period` jedinica vremena, nakon početne aktivacije
- `akcija` predstavlja funkciju koju treba pozvati pri aktivaciji alarma.

U sustavima s ovakvom jednostavnom jezgrom mogu se kombinirati razni mehanizmi upravljanja. Za periodičke poslove mogu se koristiti alarmi, svaki sa svojim budućim trenutkom aktivacije i periodom ponavljanja. Asinkroni događaji mogu se upravljati iz prekidnih funkcija, a svi ostali dijelovi sustava korištenjem upravljačke petlje. Odgoda programa može se ostvariti podsustavom upravljanja vremenom, npr. funkcijom `odgodi(t)` umjesto radnim čekanjem, kao što je korišteno u prethodnim primjerima.

Prethodne konstrukcije:

```
t1 = ažuriraj_vrijeme()
...
ponavljaj
  t2 = ažuriraj_vrijeme()
dok je t2 < t1 + odmak
```

mogu se zamijeniti s:

```
t1 = dohvati_vrijeme()
...
odgodi_do(t1 + odmak)
```

Korištenje relativne odgode s `odgodi(odmak)` treba izbjegavati zbog mogućeg gomilanja greške jer se ne uzima u obzir trajanje izvođenja programa, koje iako je vjerojatno kratko u jednoj iteraciji petlje ipak postaje značajno nakon mnogo iteracija.

Korištenjem jednostavne jezgre upravljanje se jednostavnije ostvaruje, a moguće je ostvariti i složenija upravljanja koja bez jezgre nisu bila moguća.

U nastavku slijedi nekoliko primjera koji koriste ovakvu jezgru.

Primjer 3.7. Periodičko očitanje senzora alarmima

Prethodni primjeri s periodičkim očitanjem senzora i reakcijom na njih korištenjem upravljačke petlje (3.4. i 3.5.) mogu se u sustavu s jednostavnom jezgrom ostvariti postavljanjem četiri alarma prema sljedećem kôdu.

```
T[i] = { 30, 40, 20, 100 } # periode

inicijaliziraj()
  inicijaliziraj_prekidni_podsustav()

  postavi_alarm(T[1], T[1], obrada_1)
  postavi_alarm(T[2], T[2], obrada_2)
  postavi_alarm(T[3], T[3], obrada_3)
  postavi_alarm(T[4], T[4], obrada_4)

  pokreni_upravljanje_ostalim_komponentama()

obrada_1()
  s = očitaj_senzor(1)
  poduzmi_akcije(1, s)

obrada_2()
```

```
...
```

Kada očitanja, proračuni ili pokretanje akcija ne bi bili kratki, reakcija na neke događaje određene komponente (koji se u ovom načinu otkrivaju očitanjem senzora) bi mogla biti neprihvatljivo duga, a sve zbog čekanja na dovršetka obrade prijašnjih komponenata u lancu. U takvoj situaciji bilo bi potrebno razmišljati o dodavanju prioriteta pojedinim funkcijama i traženju sučelja koja to nude.

Primjer 3.8. Upravljanje alatnim strojem

Neka se neki alatni stroj može upravljati programski, korištenjem petlje, uz povremene odgode zadavanja naredbi. Pri radu, zbog raznih razloga (loš program, nekvaliteta alata, tvrdoća predmeta koji se obrađuje i slično) može se dogoditi da se alat pregrije. Za takve situacije postoji senzor koji će mehanizmom prekida signalizirati računalu da treba privremeno zaustaviti rad dok se alat ne ohladi. Sljedeći odsječak kôda može poslužiti kao idejno rješenje upravljanja.

```
upravljanje()
  poveži_prekid(PREKID_PREGRIJAVANJA, pregrijavanje)
  inicijalizacija_svega_ostalog()
  ...
  # dio koda koji se aktivira po pokretanju operacije
  p = učitaj_naredbe()
  za i = 1 do p.broj_naredbi radi
    postavi_naredbu(p.naredba[i])
    odgodi(p.trajanje[i])
    dok je p.očitaj_stanje() != p.očekivano_stanje[i] radi
      odgodi(p.odgoda[i])
    dok je stanje() == ZAUSTAVLJEN radi
      čekaj naredbu NASTAVI
  ...

# funkcija koja se poziva iz prekida senzora za pregrijavanje alata
pregrijavanje()
  postavi_naredbu(STANI | HLAĐENJE)
  postavi_alarm(Th, 0, nastavi)

# po isteku prethodnog alarma
# (alat se dovoljno ohladio da može dalje raditi)
nastavi()
  postavi_naredbu(NASTAVI)
```

Mnoga razvojna okruženja (IDE) namijenjena za razvoj ugradbenih sustava sadrže upravo ovakvu ili vrlo sličnu jezgru. Jedno od njih je i Arduino razvojno okruženje, prvenstveno namijenjeno hobistima koji koriste jednostavne mikrokontrolere za upravljanje nekim dijelom sustava. Primjer 3.9. prikazuje moguću strukturu koda u takvom okruženju.

Primjer 3.9. Ostvarenje upravljanja kroz Arduino razvojno okruženje

Pretpostavimo da ugradbeno računalo treba upravljati s tri periodičke aktivnosti te reagirati na dva različita događaja. U Arduino okruženju programsko rješenje bi moglo biti sljedeće.

```
//periode
const unsigned long T1 = 50;
const unsigned long T2 = 100;
const unsigned long T3 = 75;
//vremena iduće aktivacije
unsigned long t1, t2, t3;

//prekidi - pinovi
const byte Pr_1_pin = 2;
const byte Pr_2_pin = 3;

//funkcija koja se pokreće samo jednom pri inicijalizaciji
void setup() {
  //inicijalizacije periodičkih aktivnosti
  t1 = milis() + T1;  //prvi puta nakon T1
  t2 = milis();   //prvi puta odmah
  t3 = milis() + T3;  //prvi puta nakon T3

  //inicijalizacije prekida
  pinMode(Pr_1_pin, INPUT_PULLUP);
  attachInterrupt(digitalPinToInterrupt(Pr_1_pin), Prekid_1, CHANGE);
  pinMode(Pr_2_pin, INPUT_PULLUP);
  attachInterrupt(digitalPinToInterrupt(Pr_2_pin), Prekid_2, CHANGE);
}

//funkcija koja se poziva cijelo vrijeme, u petlji
void loop() {
  //"prozivanje" periodičkih aktivnosti, one provjeravaju je li im vrijeme
  p1();
  p2();
  p3();
}

//funkcija za prvu periodičku aktivnost
void p1() {
  if (milis() < t1)
    return;
  //vrijeme je došlo za pokretanje ove aktivnosti
  ...
  t1 = t1 + T1;
}
//slično i za p2() i p3()

void Prekid_1() {
  //promjena na pinu Pr_1_pin, obradi događaj
  ...
}
//slično i za Prekid_2()
```

Prekidi, alarmi i petlja mogu poslužiti za upravljanje mnogim sustavima, čak i vrlo složenima. Ipak, porastom složenosti sustava raste i složenost ostvarenja upravljanja.

Upravljanje nezavisnim elementima sustava može se zasnivati na korištenju struktura podataka koje sadrže stanje pojedinih elemenata, kao što je to već pokazano primjerom 3.6. Upravljanje se svodi na petlju u kojoj se te strukture podataka ažuriraju protokom vremena i stanjem naprava (senzora), te po potrebi pokreću odgovarajuće akcije. Stanje elementa sustava kojim se upravlja zapisano je u strukturi podataka te je akcija ovisna o stanju. Prethodni primjer s alatnim strojem jedan je jednostavniji primjer takvog upravljanja. U prethodnom poglavlju je prikazano upravljanje liftovima kroz upravljačku petlju te opsežniju strukturu podataka koja

opisuje stanje sustava. U još složenijim sustavima bi se takvo upravljanje još moglo proširiti prekidima i alarmima.

3.1.4. Višedretvenost

U složenim sustavima često ima više posla za obradu svakog elementa, oni mogu imati različita vremenska svojstva, različito značenje za sustav i slično. Korištenje prethodno opisanih mehanizama (petlja, prekidi, alarmi) za ostvarenje takvih sustava ima nekoliko nedostataka.

Jedan od njih je neefikasnost jer se svaki element svakim prolaskom kroz petlju ponovno u potpunosti evaluira. Kada bi pojedinim elementom upravljali zasebnim kôdom (dretvom) tada bi stanje izvođenja tog kôda (gdje se nalazimo u programu) definiralo i stanje – ne bi trebalo to ponovno utvrđivati.

Drugi nedostatak je osiguranje vremenskih svojstava. U petlji se elementi obrađuju slijedno što znači da vrijeme potrošeno na jedan element ima utjecaja na drugi. U nekim situacijama bi se tome moglo doskočiti korištenjem alarma i prekida, ali ne uvijek.

Navedeni problemi bi se mogli riješiti višedretvenošću, gdje bi zasebnim elementom upravljali zasebnom dretvom, sa svojim kodom i prioritetom. Ali to naravno znači i veće zahtjeve prema sustavu, i više memorije i dodatni kod u jezgri.

3.1.4.1. Kooperativna višedretvenost

Proširenje jezgre podsustavom za višedretvenost je značajno proširenje koje velikim dijelom mijenja i ostale podsustave.

Ponekad se jednostavniji oblici višedretvenosti mogu ostvariti i bez podrške jezgre operacijskog sustava, ostvarenjem višedretvenosti unutar samog programa. Potrebne dretve mogu se "ugraditi" u program te prelazak s jedne dretve na drugu (zamjena aktivne dretve) ostvariti izravnim pozivima u programu. Prelaz s jedne dretve na drugu pretpostavlja pohranu konteksta prve i obnovu konteksta druge dretva. Upravljanje sustavom korištenjem kooperativne višedretvenosti ilustrirano je slikom 3.4.

Izravno raspoređivanje dretvi

Zamjena dretva može biti izravna, gdje dretva A izravno predaje kontrolu dretvi B (A traži da ga B zamijeni). Primjerice, preko sučelja `nastavi_dretvu_B()` dretva A prepušta procesor dretvi B. Ovakvo izravno raspoređivanje dretvi mora se programirati u kôd upravljačkog programa. Takva višedretvenost je najjednostavnija za ostvariti, ali i s najviše ograničenja. Idući primjer prikazuje jedno takvo rješenje.

Primjer 3.10. Primjer izravnog raspoređivanja

```
dretva A
  ponavljaj
    obrada_A1()
    nastavi_dretvu_B()
    obrada_A2()
    dok je uvjet1 radi
      nastavi_dretvu_B()
```

```
dretva B
  ponavljaj
    obrada_B1()
    nastavi_dretvu_A()
    obrada_B2()
    ako je uvjet2 tada
      nastavi_dretvu_A()
```

Naizgled bi se `nastavi_dretvu` mogao zamijeniti skokom. Međutim, uvjeti onemogućuju obične skokove. Mogli bi pamtiti do kuda su stigle pojedine dretve prije skoka, ali to

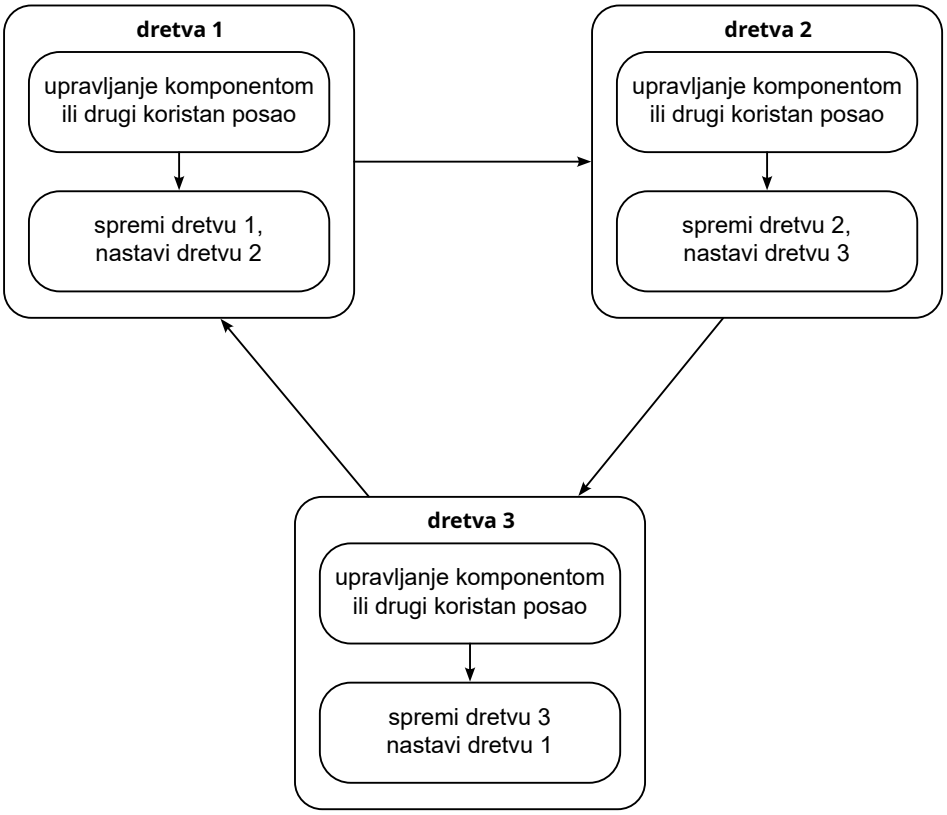

Slika 3.4. Ostvarenje upravljanja kooperativnom višedretvenošću

je zapravo dio konteksta dretve, odnosno to i je neki oblik kooperativne višedretvenosti.

Izravno raspoređivanje načelno je vrlo slično prikazanom pristupu upravljanja sustavom s više elemenata u primjeru 3.6. Jedino što je sada očitiji način upravljanja pojedinim elementom jer su naredbe koje se tiču jednog elementa napisane jedna iza druge.

Neizravno raspoređivanje dretvi

Uz dodatnu podatkovnu strukturu (npr. jednostavnu listu) moglo bi se programski ostvariti (izvan jezgre operacijskog sustava) i općenitije upravljanje dretvama, tj. raspoređivanje kod kojeg nije potrebno izravno odrediti iduću dretvu, već se ona određuje iz skupa dretvi (npr. prva iz liste). U takvim sustavima dretve mogu imati i različite prioritete, a dovoljno sučelje može biti `prepusti_procesor()` (engl. *`yield()`*). Primjer 3.10. bi se u takvom sustavu mogao preinačiti u 3.11.

Primjer 3.11. Primjer neizravnog raspoređivanja

```
dretva A
  ponavljaj
    obrada_A1()
    prepusti_procesor()
    obrada_A2()
    dok je uvjet1 radi
      prepusti_procesor()
```

```
dretva B
  ponavljaj
    obrada_B1()
    prepusti_procesor()
    obrada_B2()
    ako je uvjet2 tada
      prepusti_procesor()
```

Kada bi u sustavu za primjer 3.11. bilo više dretvi, npr. još i dretve C, D i E, tada bi se za svaki poziv prepuštanja procesora iduća dretva odredila uvidom u dodatnu podatkovnu strukturu, tj. odabir iduće dretve nije "programiran" kod svake dretve. Mogućnosti za upravljanje korištenjem neizravnog raspoređivanja su zato značajno veća nego kod izravnog raspoređivanja.

Treba primijetiti da u oba prikazana načina kooperativne višedretvenosti dretve same odlučuju *kada* će prepustiti procesor drugoj dretvi, tj. odluka *kada* je programirana. Ovakvo raspoređivanje nazivamo i neprekidivim (engl. *non preemptive*) jer trenutno aktivnu dretvu ne može prekinuti neka druga. Naravno, u sustavima koji imaju prekidni podsustav sami prekidi će prekidati izvođenje dretvi, ali će se nakon obrade prekida kontrola vratiti u istu prije prekinutu dretvu, a ne neku drugu, što je možda potrebno u nekim sustavima.

Primjerice, ako pretpostavimo da u prethodnom primjeru dretva A obavlja vrlo bitan posao u svom prvom dijelu `obrada_A1`, manje bitan u `obrada_A2` te da `uvjet1` postavlja neka funkcija koja se poziva u obradi prekida. Ako je potrebno da reakcija dretve A treba biti vrlo brza odrada dijela `obrada_A1`, ovakav kooperativni način upravljanja dretvi možda neće biti odgovarajući. Naime, osim što će se u obradi prekida naprave poništiti `uvjet1`, nakon obrade vratit će se u onu dretvu koja je bila prekinuta. Ta dretva može biti i dretva B, te dretva A neće doći na red dok joj B to sama ne prepusti.

Ovakvo ograničenje može se riješiti jedino ugrađivanjem podrške za višedretvenost u jezgru, odnosno samo raspoređivanje treba ostvariti u jezgri, uklopiti ga u sve podsustave, kao što je to i prekidni podsustav.

3.1.4.2. Višedretvenost ostvarena u jezgri

Višedretvenost ostvarena u jezgri operacijskog sustava omogućuje ostvarenje i vrlo složenih sustava upravljanja. Primjerice, prekidom neke naprave sustav može propustiti trenutno blokiranu dretvu koja je upravo čekala na događaj naprave i nastaviti s njenim radom ako je njen prioritet veći od prethodno aktivne dretve (prekinute prekidom). Takve sustave nazivamo *prekidljivim* ili *istiskujućim* (engl. *preemptive*). Dretve u tom sustavu mogu osim u aktivnom i pripravnom stanju (kao i kod kooperativne višedretvenosti) biti i u blokiranom stanju, gdje čekaju na događaj UI naprave, sinkronizacijski mehanizam, protok vremena ili slično.

S obzirom na to da višedretvenost podrazumijeva raspoređivanje dretvi (prema prioritetu i drugim kriterijima), mehanizme sinkronizacije i međusobne komunikacije dretvi, zaštitu jedne dretve od druge i slično, potreban je "pravi operacijski sustav". Kada se upravljanje ne može ostvariti na jednostavnije načine tada je najbolje odabrati neki od postojećih operacijskih sustava za SRSV koji, pored ostalih mogućnosti, standardno dolaze s podrškom za višedretvenost i pripadne funkcionalnosti. Načelna arhitektura upravljanja koje koristi višedretvenost prikazana je na slici 3.5.

Višedretvenost se može koristiti na nekoliko načina radi pojednostavljenja upravljanja.

Osnovni način jest da se za pojedine komponente sustava koristite zasebne dretve koje će njima upravljati i tako svu funkcionalnost ostvariti na jednom mjestu ("podijeli i vladaj"). Svaka dretva može imati vlastiti način upravljanja, npr. koji koristi trenutno stanje elementa i sustava, čitati potrebne ulaze i podatke o željenom ponašanju te slati potrebne naredbe.

Za neke probleme ponekad je jednostavnije dijelove upravljanja izravno ugraditi nego li stalno provjeravati ulaze i proračunavati iduće poteze. Primjerice, ako je poznato da od jednog stanja do željenog budućeg stanja sustavom treba upravljati na točno zadani način i da (skoro) ništa što se na ulazu može pojaviti to ne može promijeniti, onda se niz potrebnih naredbi za takvu promjenu stanja može ugraditi u upravljanje dretve. "Ugradnja" ne mora biti isključivo programska – nizom instrukcija, već i korištenjem strukture podataka (npr. lista naredbi više

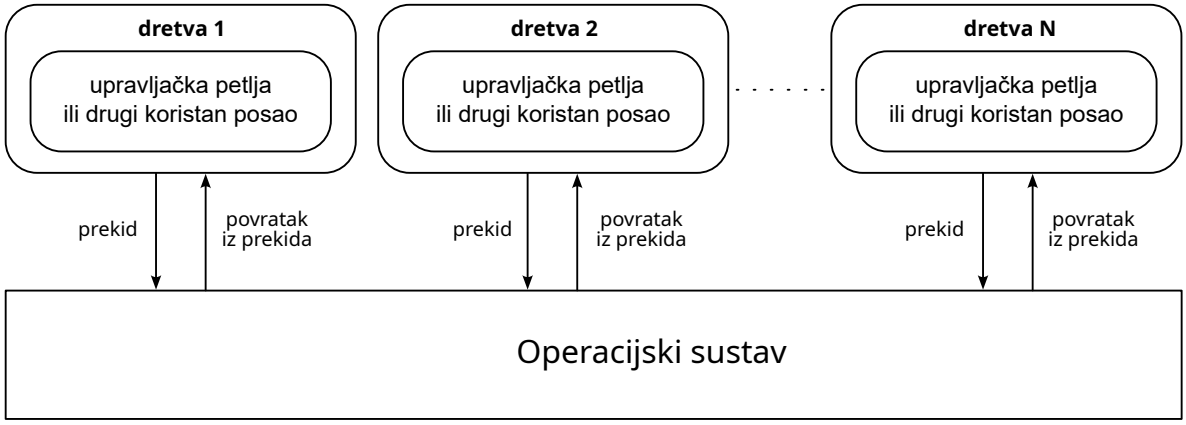

Slika 3.5. Ostvarenje upravljanja pomoću operacijskog sustava i višedretvenosti

razine). Upravljanje u dretvi se tada pojednostavljuje: ona otkriva takva stanja i ulazi u način rada izvođenja operacije po operacije do dostizanja željenog stanja. Navedeni mehanizam nije ograničen samo na višedretvena ostvarenja.

U nekim se sustavima upravljanje može ostvariti i hijerarhijski. Odluke o operacijama mogu se donositi na najvišoj razini dok se za njihovo sprovođenje trebaju stvarati odluke na nižim razinama. Primjerice, za lift se na najvišoj razini može odlučivati o tome gdje lift treba stati dok se na nižim razinama to sprovodi u slanje poruka, primanje poruka, zadržavanje i slično.

Pri ostvarivanju sustava korištenjem dretvi u okviru operacijskih sustava za SRSV treba pripaziti na raspoređivanje dretvi, sinkronizaciju, komunikaciju, korištenje podataka u zajedničkom spremniku te utrošak vremena koje jezgra koristi za upravljanje dretvama. Navedeni su problemi detaljnije razmotreni u idućim poglavljima.

3.1.5. Raspodijeljeni sustavi

Mnogi SRSV-i se sastoje od više komponenata (ili čvorova, engl. *nodes*) kojima zasebno upravlja vlastiti računalni sustav. Svaka komponenta "komunicira" s ostalim komponentama neizravno, korištenjem svojih senzora, detekcijom promjena koje su posljedica djelovanja drugih komponenata. Ipak, često je potrebna i izravna komunikacija i razmjena informacija i naredbi. Takva komunikacija treba biti podržana odgovarajućim podsustavom koji ostvaruje potrebne protokole.

Ostvarenje upravljanja u pojedinoj komponenti raspodijeljenog sustava može biti ostvareno bilo kojim od prethodnih načina. Informacije koje dolaze od drugih komponenata mogu se smatrati kao podaci s ulaznih naprava.

Međutim, posebnost raspodijeljenog sustava je u vremenu odziva. Ulazno-izlazne naprave spojene na jedan računalni sustav su upravljane tim sustavom i njihova se reakcija može poprilično dobro predvidjeti. U raspodijeljenom sustavu vremena odziva pojedinih komponenti mogu biti znatno veća, ali i što je zapravo problem, njihovo trajanje može biti vrlo teško predvidjeti. Posebice je to istaknuto ako su komponente daleko jedna od druge i za komunikaciju koriste nepouzdane kanale ili protokole koji nemaju prikladnu podršku za vremensko usklađenu komunikaciju i signalizaciju, primjerice ako koriste Internet ili čak i zatvoreni sustav ali koji koristi iste protokole. Osnovni problem raspodijeljenih sustava jest u teškom određivanju trajanja pojedinih operacija za najgore moguće slučajeve (što svakako treba razmatati za SRSV-e).

U sustavu s više komponenata, sa složenim načinom komunikacije, te strogim vremenskim

ograničenjima, projektiranje raspodijeljenih sustava postaje izazov, tj. izrazito težak problem.

3.2. Ostvarenje regulacijskih zadataka

Upravljanje mnogih SRSV-a podrazumijeva i *automatsko upravljanje* dijelom podsustava tako da se taj dio ponaša u skladu s očekivanjima. Primjer su sustavi za održavanje brzine, smjera, temperature, tlaka, napona. Svi oni neprestano (u petlji) preko senzora očitavaju trenutne vrijednosti $y(t)$ te na osnovu postavljene (željene) vrijednosti $y_P(t)$ i algoritma usklađivanja šalju naredbe $r(t)$ koje će pokušati usmjeriti sustav prema postavljenom stanju, prema slici 3.6. Iako su na slici sve vrijednosti navedene kao skalari (jednodimenzionalne), oni mogu biti i drugi složeniji podaci (vektori, matrice, ...). Radi jednostavnosti razmatranja i u nastavku teksta će se koristiti obični skalari.

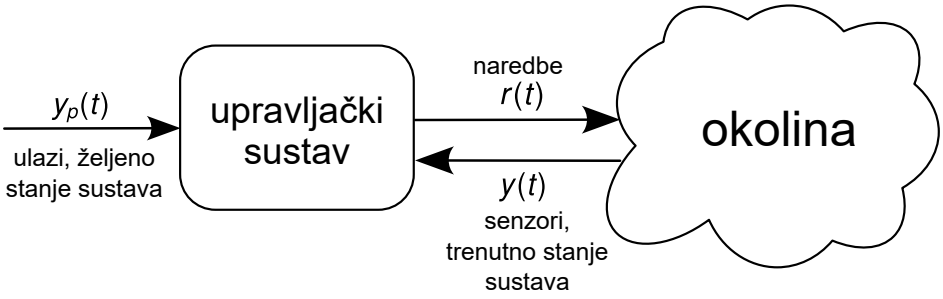

Slika 3.6. Upravljanje stanjem sustava

Upravljački dio sustava mora reagirati u stvarnom vremenu, tj. očitavati (ili računati) željeno stanje sustava, preko senzora dobiti informacije o trenutnom stanju sustava te izdavati naredbe koje će dovoditi sustav u željeno stanje, tj. smanjiti trenutna odstupanja.

Računala rade u koracima, izvode instrukciju za instrukcijom, proračunavaju i šalju naredbu za naredbom sustavu kojeg upravljaju. Također, očitanja stanja sustava obavljaju se u pojedinim trenucima vremena, diskretnim trenucima, a ne kontinuirano. Kada su ti trenuci dovoljno blizu jedan drugome (tj. frekvencija očitanja dovoljno velika[1]), promjena sustava je mala te se na svaku promjenu može dovoljno brzo reagirati (što i regulator radi). S obzirom na to da se i očitanja i naredbe izdaju u diskretnim trenucima t_k vrijednosti svih varijabli u tim trenucima mogu se izraziti kao funkcije od t_k, ili i kraće samo dodajući varijablama indeks k. Tako $\mathrm{y}_P(t)$ postaje $\mathrm{y}_{P,k}$, $\mathrm{y}(t)$ postaje y_k, $\mathrm{r}(t)$ postaje r_k i slično za ostale vrijednosti i funkcije. Integral i derivacija se aproksimiraju sumom svih i razlikom susjednih grešaka.

Problemi koje diskretizacija unosi se ovdje neće zasebno razmatrati. Uglavnom, potrebno je da se pripazi na stabilnost algoritma, odnosno da se korak integracije prikladno odabere u skladu s odabranim postupcima (npr. postupkom numeričke integracije).

3.2.1. Upravljanje bez povratne veze

Ponekad informacije o trenutnom stanju sustava nisu potrebne ili nisu dostupne. Primjerice, pri upravljanju protokom kroz neku slavinu potrebno stanje slavine za željeni protok se može proračunati (uz poznati pritisak/tlak tekućine). Stvarni će protok biti jednak proračunatom te očitanje stvarnog protoka i nije neophodno.

Za neke složenije sustave, koji su pod stalnim nadzorom (i/ili upravljanjem) čovjeka (npr. preko

[1]Prema Nyquist Shannonovu teoremu frekvencija uzorkovanja treba biti barem dvostruko veća od frekvencije signala kojeg se uzorkuje (njegovog najvišeg harmonika), a da bi se signal mogao u potpunosti obnoviti.

upravljačke palice), povratna informacija o stanju sustava i nije neophodna s obzirom na to da će čovjek zadavati odgovarajuće naredbe koje će usmjeriti sustav u željenom smjeru.

U oba prethodna primjera upravljačko računalo stvara naredbe samo na osnovu ulaza, tj. podataka o željenom stanju sustava te takva upravljanja nazivamo *upravljanja bez povratne veze*.

Matematički gledano, izlazne naredbe $\mathrm{r}(t)$ koje računalo stvara pri upravljanju bez povratne veze su funkcija samo ulaza $\mathrm{y_P}(t)$, prethodnog proračunatog stanja $\mathrm{u}(t)$ te eventualno i protoka vremena t te se mogu iskazati funkcijski prema (3.1.).

$$\mathrm{r}(t) = \mathrm{F}(\mathrm{y_P}(t), \mathrm{u}(t), t) \tag{3.1.}$$

Funkcija F ovisi o problemu i može biti jednostavna ili složena. Za jednostavnija upravljanja funkcija F može ovisiti samo o ulazu $\mathrm{y_P}$ i to najčešće linearno te se može zapisati prema (3.2.).

$$\mathrm{r}(t) = K_1 \cdot \mathrm{y_P}(t) + K_0 \tag{3.2.}$$

I složeniji sustavi se u okolini upravljačke točke uglavnom mogu aproksimirati linearnom funkcijom te se upravljanje i tada može ostvariti jednostavnim mikrokontrolerom.

3.2.2. Upravljanje uz povratnu vezu

Sustavi koji nisu pod stalnim nadzorom čovjeka i koji ne upravljanju procesima za koje se može predvidjeti ponašanje moraju u stvaranju naredbi uzeti u obzir trenutno stanje sustava, tj. moraju koristiti *povratnu vezu* (očitano stanje $\mathrm{y}(t)$). Ekvivalentno funkciji (3.1.), za sustave s povratnom vezom može se definirati funkcija (3.3.) kojom se izračunavaju naredbe, tj. vrijednosti koje se šalju aktuatorima koji upravljaju sustavom.

$$\mathrm{r}(t) = \mathrm{F}(\mathrm{y_P}(t), \mathrm{y}(t), \mathrm{u}(t), t) \tag{3.3.}$$

S obzirom na to da se koristi povratna veza, upravljačko računalo prilagođava svoje izlaze trenutnom stanju sustava i time *regulira* (prilagođava) ponašanje sustava, tj. obavlja funkciju *regulatora*. Regulatori mogu biti ostvareni na razne načine. Za ostvarenja osnovnih regulatorskih zadataka često se koriste *PID regulatori*. Za složenije sustave kod kojih se funkcija upravljanja ne može egzaktno iskazati mogu se koristiti i postupci koji se zasnivaju na *neizrazitom zaključivanju* (engl. *fuzzy logic*). U nastavku su ukratko prikazana načela oba pristupa.

3.3. PID regulator

PID regulator svoje upravljanje zasniva na odstupanju, tj. razlici između željenog stanja $\mathrm{y_P}(t)$ i trenutnog stanja $\mathrm{y}(t)$, tj. na trenutnom odstupanju $\mathrm{e}(t)$. Sve se vrijednosti mogu mijenjati s vremenom te su i naznačene kao funkcije vremena t. Naredbe koje regulator izdaje su funkcije od trenutna odstupanja $\mathrm{e}(t)$ i njene povijesti $\mathrm{u}(t)$.

$$\mathrm{e}(t) = \mathrm{y}_P(t) - \mathrm{y}(t) \tag{3.4.}$$

$$\mathrm{r}(t) = \mathrm{F}(\mathrm{e}(t), \mathrm{u}(t)) \tag{3.5.}$$

PID regulator svoje ime dobiva od tri komponente funkcije F. One su:

- P – proporcionalna komponenta
- I – integracijska komponenta i
- D – derivacijska komponente.

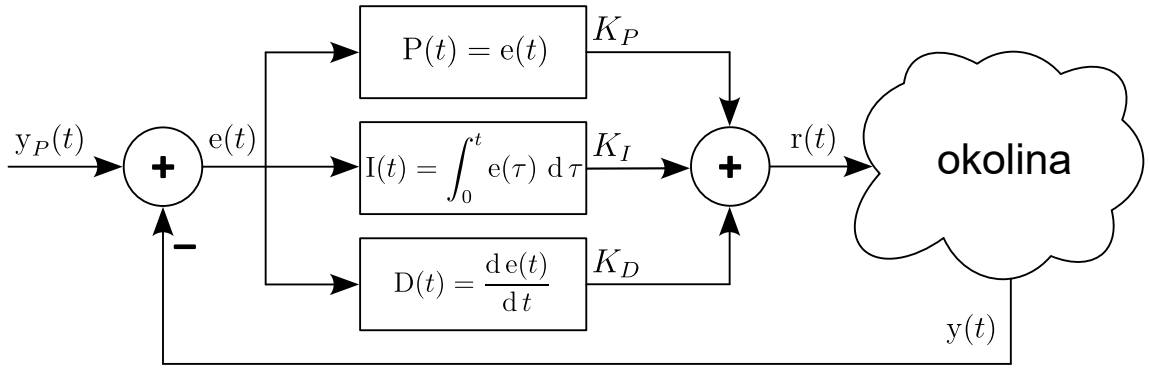

Slika 3.7. PID regulator

Slika 3.7. prikazuje najjednostavniju izvedbu PID regulatora.

Izlaz iz navedena regulatora dobiva se zbrajanjem svih komponenti prema formuli 3.6.

$$\mathrm{r}(t) = K_P \cdot \mathrm{e}(t) + K_I \int_0^t \mathrm{e}(\tau)\ \mathrm{d}\,\tau + K_D \frac{\mathrm{d}\,\mathrm{e}(t)}{\mathrm{d}\,t} \tag{3.6.}$$

Osim PID regulatora koji sadrži sva tri elementa, za neke se primjene mogu koristiti i samo P ili PI ili PD regulatori sa samo nekim od te tri komponente.

3.3.1. Proporcionalna komponenta – P

Osnovna komponenta regulatora je proporcionalna koja treba ispraviti odstupanje sustava od željenog stanja. Parametar K_P se podešava prema potrebnoj brzini uspostave željenog stanja. Što je K_P veći to će reakcija biti brža, i obratno, što je K_P manji to će se sustav sporije približavati željenom stanju. Pri odabiru prave vrijednosti tog parametra (a i ostalih) treba koristi modele ponašanja sustava i/ili heuristiku i/ili ispitivanja. Prevelika vrijednost K_P može dovesti do nestabilnosti, dok premala vrijednost možda neće biti dovoljna da se sustav dovede u željeno stanje (zbog otpora u sustavu). Primjerice, ako je K_P preveliki reakcija na grešku može uzrokovati još veću grešku, ali drugog predznaka, ova pak još veću itd.

Problemi regulatora koji imaju samo P komponentu se u nekim sustavima javljaju kao nemogućnost dostizanja željenog stanja sustava. Slika 3.9. prikazuje taj problem.

3.3.2. Integracijska komponenta – I

Osnovna zadaća integracijske komponente je da ubrza promjene kada se odstupanje sporo smanjuje (ili se ne smanjuje). Integracijska komponenta zbraja (integrira) prijašnje greške, te ako se greške ne smanjuju, ona vremenom sve značajnije pridonosi povećanju izlaza $\mathrm{r}(t)$. Slika 3.8. prikazuje načelo izračuna integracijske komponente na osnovu prijašnjih odstupanja, tj. kao njihov integral.

Integracijska komponenta će ponekad riješiti i problem odstupanja od željene vrijednosti koje može nastati uporabom samo P regulatora. Integracijski parametar K_I treba biti pažljivo odabran jer će u protivnom dovesti do istih problema kao i neprikladan parametar K_P.

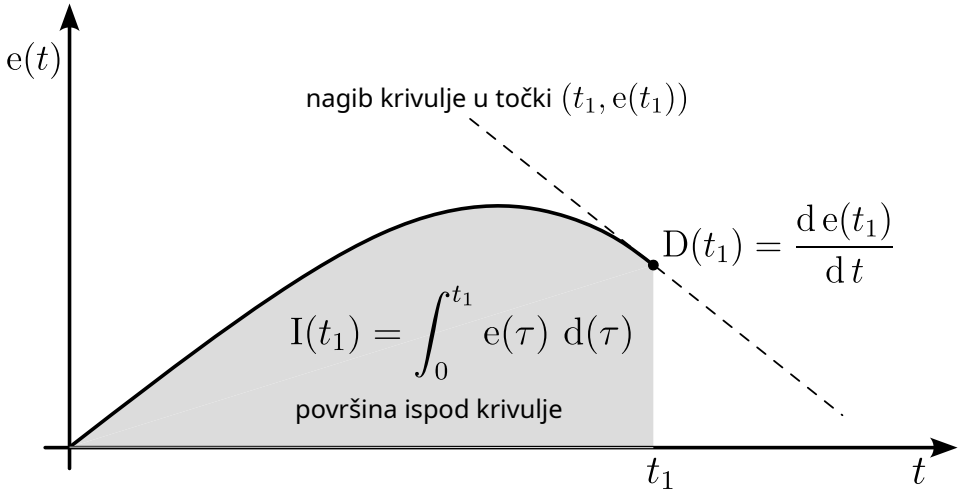

Slika 3.8. Izračunavanje integracijske i derivacijske komponente

3.3.3. Derivacijska komponenta – D

Kada reakcija na odstupanja mora biti promptnija (brža) tada se i K_P ili K_I moraju povećavati. Jedan od problema koje to može uzrokovati su oscilacije oko željenog stanja sa sporim prigušenjem. Osnovni zadatak derivacijske komponente jest da smanji oscilacije i da ubrza stabilizaciju sustava. Parametar K_D mora se odabrati tako da donekle smanji brzinu promjene koju stvaraju proporcionalna i integracijska komponenta. Preveliki K_D može dovesti sustav do nestabilnog stanja zbog preburne reakcije na promjene. Derivacijska komponenta izračunava se kao derivacija trenutna odstupanja, prema slici 3.8.

Slika 3.9. prikazuje primjer s utjecajem proporcionalne, integracijske i derivacijske komponente na izlaz $\mathrm{y}(t)$. Običan P regulator ne dostiže željeno stanje sustava, PI dostiže, ali najprije oscilira oko njega, dok PID s derivacijskom komponentom prigušuje osciliranje ili ga u potpunosti eliminira kao na slici.

3.3.4. Diskretni PID regulator

Kod diskretnog PID regulatora koriste se diskretni trenutci t_k za upravljačke odluke, odnosno oznaku vremena. Sve varijable/funkcije dobivaju indeks "k" umjesto prijašnjeg "(t)".

Uz korak diskretizacije:

$$T = t_k - t_{k-1} \tag{3.7.}$$

sve formule za diskretni PID regulator u koraku k su (3.8.)-(3.11.)

$$\mathrm{P}_k = \mathrm{e}_k = \mathrm{y}_{P,k} - \mathrm{y}_k \tag{3.8.}$$

$$\mathrm{I}_k = \mathrm{I}_{k-1} + \mathrm{e}_k \cdot T, \quad \text{uz } \mathrm{I}_0 = 0 \tag{3.9.}$$

$$\mathrm{D}_k = \frac{\mathrm{e}_k - \mathrm{e}_{k-1}}{T}, \quad \text{uz } \mathrm{e}_0 = 0 \tag{3.10.}$$

$$\mathrm{r}_k = K_P \cdot \mathrm{P}_k + K_I \cdot \mathrm{I}_k + K_D \cdot \mathrm{D}_k \tag{3.11.}$$

Slika 3.7. se za diskretni PID regulator transformira u sliku 3.10.

Osim problema s odabirom prikladnih parametara K_P, K_I i K_D za postizanje željenog stabilnog načina upravljanja, diskretni sustav dodatno muči sama diskretizacija i problemi zbog toga. U

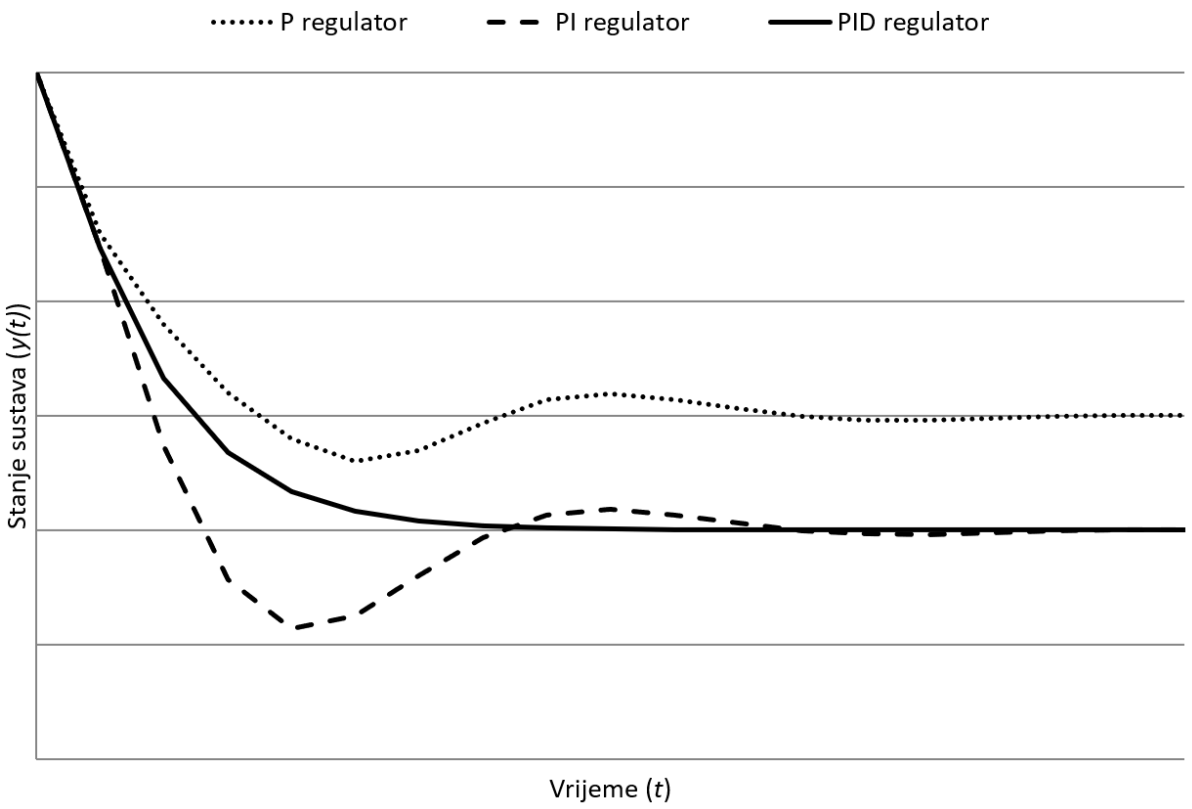

Slika 3.9. Načelni utjecaj komponenata PID regulatora

okviru ova prikaza PID regulatora ti se problemi ne razmatraju. Problem odabira i optimiranja parametara PID regulatora su složeni problemi koji su detaljnije obrađeni u drugoj literaturi. U okviru primjera koji slijede korištena je jednostavna metoda pokušaja i promašaja pri odabiru parametara s obzirom na to da su za ponašanje sustava korišteni jednostavniji modeli.

Primjer 3.12. Regulacija brzine PID regulatorom

Razmotrimo diskretan regulator koji upravlja motorom (npr. elektromotorom) u svrhu postizanja i održavanja željene brzine vozila. Neka upravljana veličina r_k (u trenutku t_k) koju regulator podešava bude promjena vrijednosti gasa g_k. Regulator upravlja samo preko r_k. Sve ostale formule i vrijednosti ovdje služe za simulaciju reakcije sustava, tj. sam PID regu-

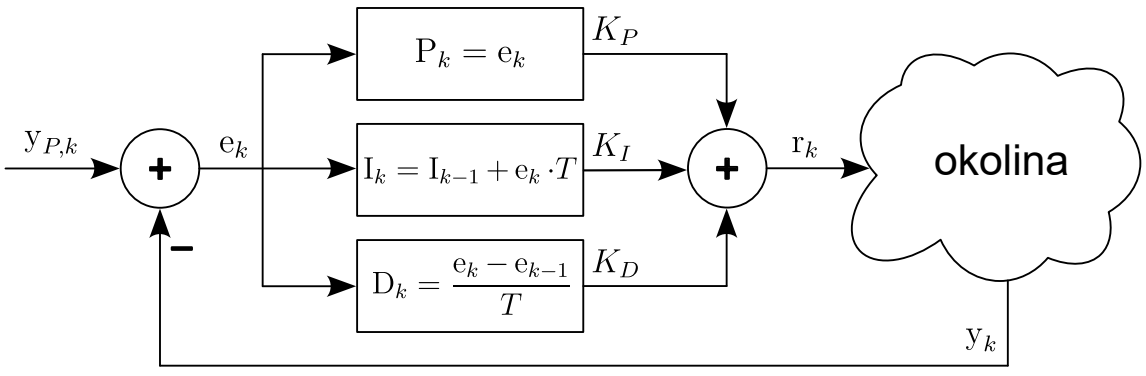

Slika 3.10. Diskretni PID regulator

lator i dalje koristi iste formule (3.8.)-(3.11.). Neka se u simulaciji sustava promjena gasa računa prema (3.12.).

$$\mathrm{g}_k = \mathrm{g}_{k-1} + \mathrm{r}_k, \quad \mathrm{g}_k \in [0,1] \tag{3.12.}$$

Pretpostavimo jednostavan model sustava kod kojeg je moment koji stvara motor izravno proporcionalan trenutno postavljenom gasu te da je sila kojom taj motor djeluje na ubrzanje i usporenje izravno proporcionalna tom momentu, odnosno trenutnom gasu prema (3.13.).

$$\mathrm{F}_{m,k} = K_M \cdot \mathrm{g}_k \tag{3.13.}$$

Promjeni brzine vozila neka se odupire sila koja se sastoji od nepromjenjivog dijela F_T (sila trenja) i dijela koji je proporcionalan kvadratu trenutne brzine v_k (otpor zraka).

$$\mathrm{F}_{O,k} = \mathrm{F}_T + K_O \cdot \mathrm{v}_k^2 \tag{3.14.}$$

Rezultantna sila F_k koja će ubrzavati ili usporavati vozilo ili održavati stalnu brzinu (kada je sila jednaka nuli) iskazana je formulom (3.15.) gdje je m masa vozila te a_k ubrzanje.

$$\mathrm{F}_k = m \cdot \mathrm{a}_k = \mathrm{F}_{m,k} - \mathrm{F}_{O,k} \tag{3.15.}$$

S obzirom na to da se radi o diskretnom sustavu, ubrzanje a_k se izračunava kao omjer promjene brzine i proteklog vremena te je konačna jednadžba gibanja za diskretni sustav (3.16.) gdje je T korak diskretizacije.

$$m \cdot \frac{\mathrm{v}_k - \mathrm{v}_{k-1}}{T} = K_m \cdot \mathrm{g}_k - \mathrm{F}_T - K_O \cdot \mathrm{v}_k^2 \tag{3.16.}$$

Za usporedbu, jednadžba kontinuiranog sustava bi bila (3.17.).

$$m \cdot \frac{\mathrm{d}\mathrm{v}(t)}{\mathrm{d}\,t} = K_m \cdot \mathrm{g}(t) - \mathrm{F}_T - K_O \cdot \mathrm{v}^2(t) \tag{3.17.}$$

Iz kvadratne jednadžbe (3.16.), odnosno u sređenom obliku (3.18.), može se izračunati brzina vozila u k-tom koraku, prema opisanom modelu vozila.

$$K_O \cdot \mathrm{v}_k^2 + \frac{m}{T} \cdot \mathrm{v}_k - \left(\frac{m}{T} \cdot \mathrm{v}_{k-1} + K_m \cdot \mathrm{g}_k - \mathrm{F}_T \right) = 0 \tag{3.18.}$$

S obzirom na to da su vrijednosti K_O, m i T pozitivne i brzina v_k mora biti pozitivna (ne mijenja se smjer) te se računa prema (3.19.).

$$\mathrm{v}_k = \frac{-\frac{m}{T} + \sqrt{\left(\frac{m}{T}\right)^2 + 4 \cdot K_O \cdot \left(\frac{m}{T} \cdot \mathrm{v}_{k-1} + K_m \cdot \mathrm{g}_k - \mathrm{F}_T \right)}}{2 \cdot K_O} \tag{3.19.}$$

Sve navedene formule grafički su prikazane na slici 3.11.

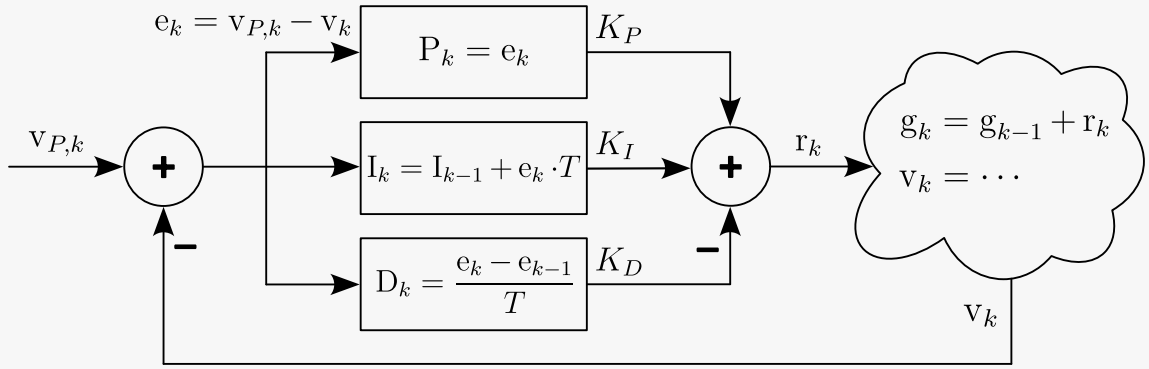

Slika 3.11.

S obzirom na to da se derivacijska komponenta odupire promjeni, ona je na prethodnoj slici dodana s negativnim predznakom (tako da sam parametar K_D bude pozitivan). Parametri koji modeliraju sustav zadani su u tablici 3.1.

Tablica 3.1.

m (masa vozila)	K_m (snaga motora)	F_T (stalan otpor)	K_O (koef. otpora)
1000 [kg]	40000 [N]	5000 [N]	20 [kg/m]

Parametre K_P, K_I, K_D te T treba podesiti tako da upravljanje bude što bliže očekivanjima. Za korak upravljanja T odabrana je vrijednost 0,1 [s] za sve iduće prikazane regulatore, tj. za različite vrijednosti ostalih parametara.

Slike 3.12.–3.14. prikazuju rezultate dobivene s P, PI i PD regulatorima brzine za sustav u kojem je početna brzina 120 [km/h], a postavljena (ciljana) brzina je 100 [km/h]. Početna vrijednost gasa g_k izračunata je preko formule 3.16. uz $v_k = v_{k-1} = 120$ km/h $= 33{,}3$ m/s.

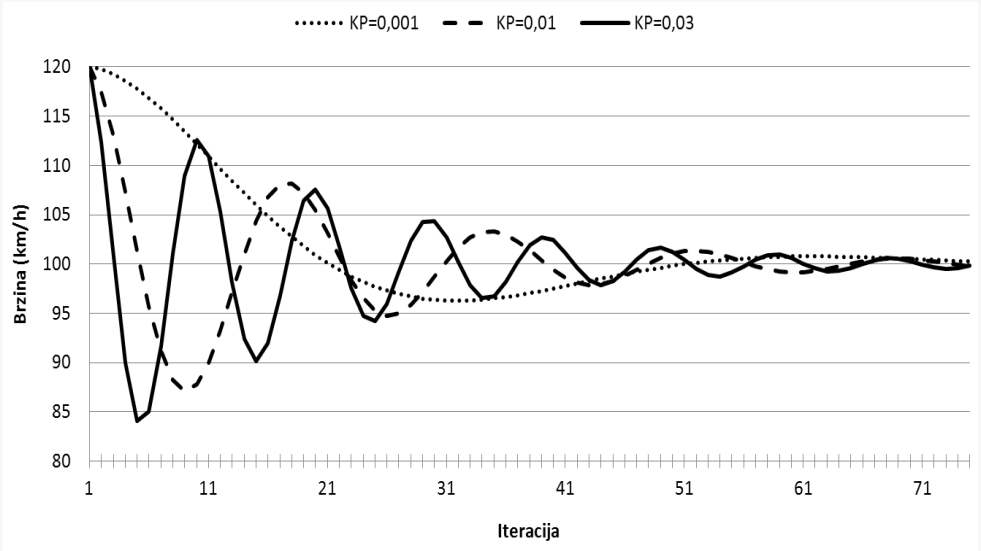

Slika 3.12. P regulator

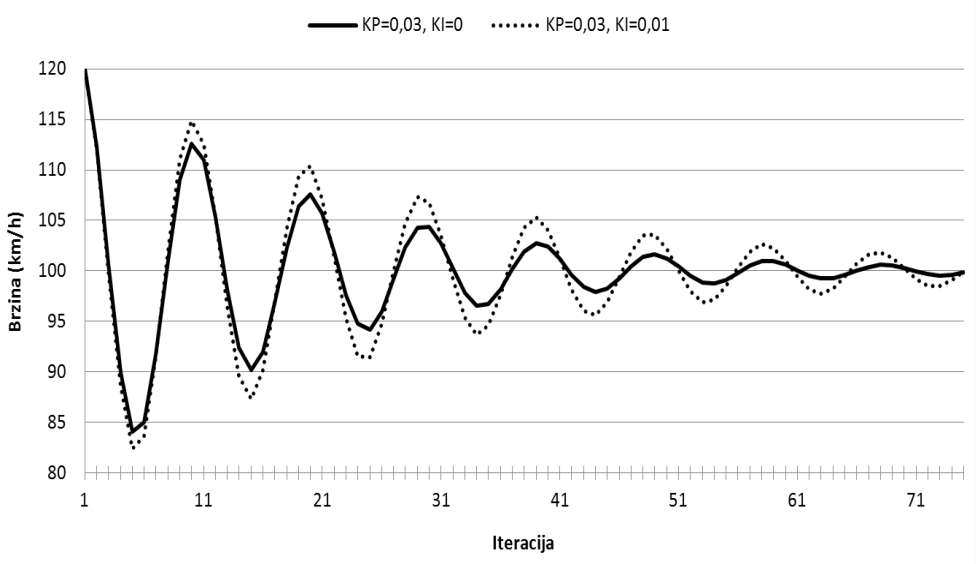

Slika 3.13. PI regulator

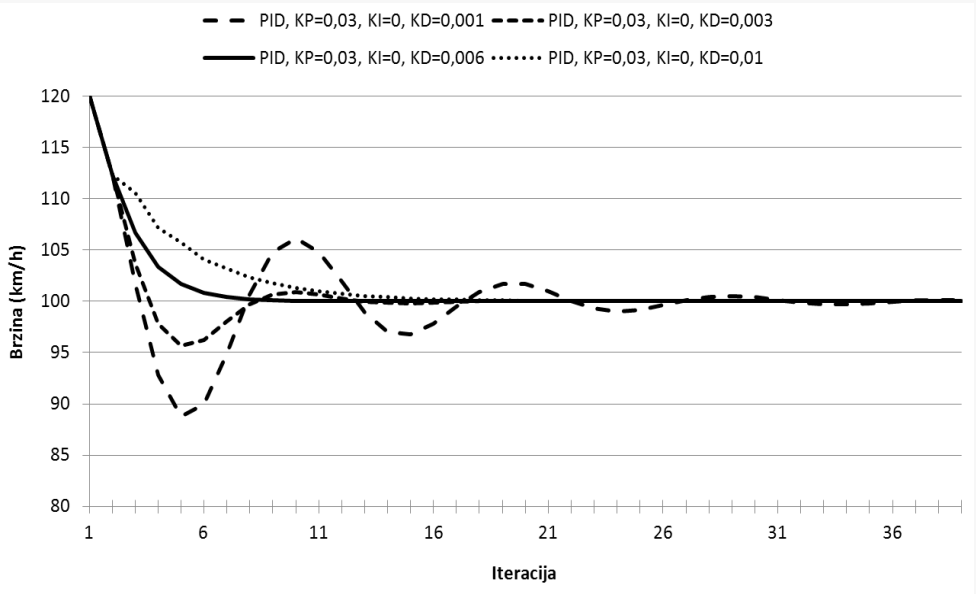

Slika 3.14. PD regulator

P regulator za sve ispitane vrijednosti K_P (osim vrlo malih) dosta oscilira prije dostizanja ciljane brzine. Prihvatljiva odstupanja postižu se tek nakon 70-tak iteracija upravljanja (otprilike 7 sekundi stvarnog vremena).

Dodavanje integracijske komponente (PI regulator) se u ovom primjeru nije pokazalo dobrim, barem za ispitane kombinacije K_P i K_I (heuristički odabrane i prilagođavane). Integracijski parametar samo povećava amplitude oscilacija u ovom primjeru.

Derivacijska komponenta je znatno ubrzala stabilizaciju sustava na željenu brzinu, što se iz slike jasno vidi (PD regulator). Treba uočiti da je vremenska skala za PD regulator skoro dvostruko kraća od one na P i PI regulatorima, tj. da je stabilizacija dvostruko brža nego što to izgleda samom usporedbom grafova. Kada bi vremenska skala bila jednaka prethodnim grafikonima, teže bi se uočila razlika, tj. utjecaj parametra K_D. Kako K_D raste tako se oscilacije prigušuju. Za prikazani sustav oscilacije su potpuno ugušene za $K_D = 0,006$. Daljnjim povećanjem parametra ublažava se postupak postizanja ciljanog stanja (brzine),

što u ovom primjeru i ima smisla jer je u protivnom prijelaz s 120 na 100 km/h prenagli (za manje od sekunde!).

3.4. Upravljanje korištenjem neizrazite logike

Sustavi kojima se upravlja mogu biti vrlo složeni. Sukladno tome će biti složena i funkcija kojom treba proračunati naredbe i vrijednosti koje se šalju u okolinu. Ponekad se zbog složenosti procesa kojim se upravlja, funkcija za određivanje izlaznih vrijednosti (naredbi) niti ne da egzaktno iskazati ili funkcija koju koristimo vrlo vjerojatno nije zadovoljavajuća zbog mnogih utjecaja koji nisu u nju uključeni te je teško njihov utjecaj iskazati u obliku formule. Čak i kada je funkcija poznata, njena složenost može zahtjevati korištenje složenijeg procesora umjesto planiranog jednostavnog mikroupravljača. Moguće rješenje za takve sustave jest korištenje neizrazitog zaključivanja (engl. *fuzzy logic*).

Neizrazitost se odražava u:

1. neizrazitom svrstavanju ulaznih vrijednosti u određene skupove
2. korištenje pravila za određivanje skupova kamo pripada izlazna vrijednost
3. postupak izračunavanja izlazne vrijednosti.

Pri definiranju skupova za ulazne i izlazne vrijednosti kao i za zaključivanja koristi se heuristika koja je vrlo blizu čovjekovu načinu razmišljanja i njegovu načinu upravljanja.

Primjerice, u nekom sustavu tekućina temperature 25 stupnjeva može pripadati u skup TOPLA s vjerojatnošću 0,25 te skupu HLADNA s vjerojatnošću 0,75, dok za skup VRUĆA vjerojatnost iznosi 0. Drugim riječima, ta temperatura ne spada samo u jedan skup, već u više njih s različitim vjerojatnostima. Stoga se i odluka o vrijednosti koju upravljač mora izračunati ne donosi samo na temelju jednog skupa, već korištenjem svih, ali uzimajući u obzir vjerojatnosti pripadnosti (koja je često zadana grafom).

Osim definicija vjerojatnosti pripadnosti za ulazne varijable, za sustav upravljanja moraju se definirati i *pravila zaključivanja* oblika:

$$p_i : \text{ako } (ulaz_a \in U_x) \text{ tada } (izlaz_c \in I_p) \tag{3.20.}$$

$$p_j : \text{ako } (ulaz_a \in U_x) \text{ i } (ulaz_b \in U_y) \text{ tada } (izlaz_c \in I_r) \tag{3.21.}$$

$$p_k : \text{ako } (ulaz_a \in U_x) \text{ ili } (ulaz_b \in U_y) \text{ tada } (izlaz_c \in I_q) \tag{3.22.}$$

S obzirom na to da ulazi pripadaju u skupove s određenom vjerojatnošću i za izlazne se vrijednosti moraju definirati skupovi i način preslikavanja vrijednosti u njih, u ovisnosti o vjerojatnosti pripadanja ulazne varijable skupu definiranome u pravilu. Jedan od mogućih postupaka neizrazitog zaključivanja – MIN_MAX je prikazan u nastavku u sklopu dva primjera.

Primjer 3.13. Upravljanje temperaturom tekućine

Pretpostavimo sustav upravljanja omjerom tople i hladne vode (nepoznatih i promjenjivih temperatura) radi postizanja željene mješavine vode zadane temperature. Iako je ovo jednostavan primjer za koji bi se možda moglo naći i jednostavnije rješenje i sam prikaz neizrazitog zaključivanja je ilustrativan.

Neka se jednim senzorom mjeri temperatura mješavine vode T na osnovu čega upravljač podešava omjer miješanja da bi se postigla ciljana temperatura $T_P = 40\ ^\circ$C. Neka su skupovi

u koje se (s različitim vjerojatnostima) smješta ulazna temperatura T te izlazni skupovi za podešavanje omjera miješanja O zadani slikom 3.15.

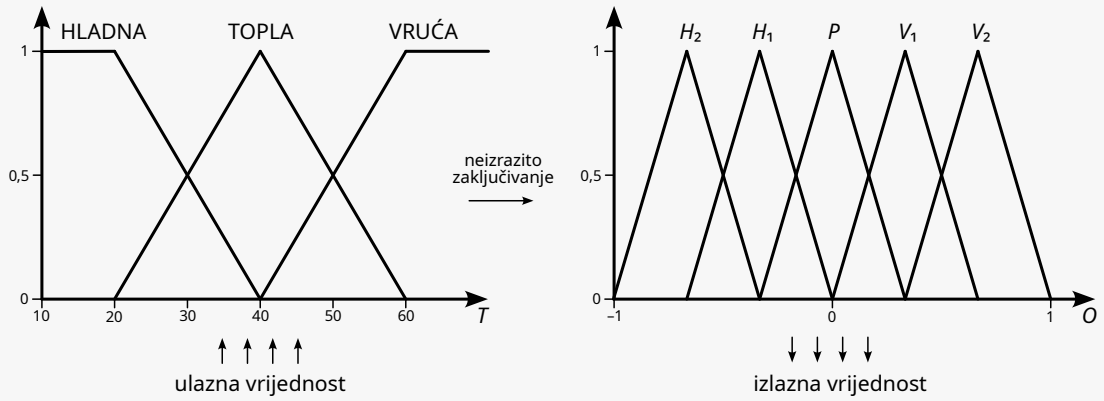

Slika 3.15.

Ulazna temperatura može pripadati skupovima HLADNA, TOPLA i VRUĆA s odgovarajućim vjerojatnostima. Npr. za T_1=15 °C vjerojatnost pripadnosti skupu HLADNA je 1, tj. μ(15 °C, HLADNA)=1; za T_2=35 °C vjerojatnost pripadnosti skupu HLADNA je μ(35 °C, HLADNA)=0,25 te vjerojatnost pripadnosti skupu TOPLA je μ(35 °C, TOPLA)=0,75; za T_2=55 °C vjerojatnost pripadnosti skupu TOPLA je μ(55 °C, TOPLA)=0,25 te vjerojatnost pripadnosti skupu VRUĆA je μ(55 °C, VRUĆA)=0,75. Sve se te vrijednosti mogu očitati iz grafa uz zadane ulazne vrijednosti temperature.

Vrijednost izlazne varijable O svrstava se u skupove od H_2 do V_2 prema slici, tako da varijabla može poprimiti vrijednosti od -1 (kada se jako povećava udio hladne vode) do 1 (kada se propušta samo vruća voda).

Preslikavanje ulazne vrijednosti preko pripadnosti skupovima (s izračunatom vjerojatnošću) na izlazne skupove i određivanje izlazne vrijednosti radi se preko određenih neizrazitih postupaka. Dio tih postupaka su pravila zaključivanja.

Za zadani primjer pravila zaključivanja bi mogla biti:

$$\begin{aligned}
&p_1 : \text{ako } (T \in \text{HLADNA}) \text{ tada } (O \in V_2)\\
&p_2 : \text{ako } (T \in \text{HLADNA}) \text{ i } (T \in \text{TOPLA}) \text{ tada } (O \in V_1)\\
&p_3 : \text{ako } (T \in \text{TOPLA}) \text{ tada } (O \in P)\\
&p_4 : \text{ako } (T \in \text{TOPLA}) \text{ i } (T \in \text{VRUĆA}) \text{ tada } (O \in H_1)\\
&p_5 : \text{ako } (T \in \text{VRUĆA}) \text{ tada } (O \in H_2)
\end{aligned} \qquad (3.23.)$$

Pravila p_2 i p_4 mogu biti suvišna (zbog pravila p_1, p_3 i p_5), ali su ipak uzeta u proračunima zbog prikaza postupka neizrazitog zaključivanja u slučaju složenih predikata.

Često korišteni postupak neizrazitog zaključivanja jest MIN_MAX kod kojeg se pravila s predikatima povezanim operatorom "i" izračunavaju primjenom minimuma, dok se operator "ili" zamjenjuje maksimumom.

Neka ulazna temperatura za koju želimo izračunati izlaz (omjer) iznosi T=32 °C. Tada se vjerojatnosti pripadnosti mogu očitati iz grafa (tj. izračunati obzirom na linearnost) i iznose: μ(32 °C, HLADNA)=0,4, μ(32 °C, TOPLA)=0,6 te μ(32 °C, VRUĆA)=0. Taj se postupak često naziva pretvaranje *izrazite vrijednosti* (skalara, fizičke veličine) u *neizrazitu vrijednost* (engl. *fuzzification*).

Primjenom prethodnih pravila dobivaju se vrijednosti:

$$\begin{aligned} p_1 &\Rightarrow \mu_{1,V2}(T) = 0,4 \\ p_2 &\Rightarrow \mu_{2,V1}(T) = \min\{0,4; 0,6\} = 0,4 \\ p_3 &\Rightarrow \mu_{3,P}(T) = 0,6 \\ p_4 &\Rightarrow \mu_{4,H1}(T) = \min\{0,6; 0\} = 0 \\ p_5 &\Rightarrow \mu_{5,H2}(T) = 0 \end{aligned} \tag{3.24.}$$

Svaka se dobivena vrijednost vjerojatnosti pripadnosti (μ) odgovarajućem izlaznom skupu ($H_2 - V_2$), bilježi u tom skupu kao dio površine skupa ispod izračunate vrijednosti vjerojatnosti, prema slici 3.16.

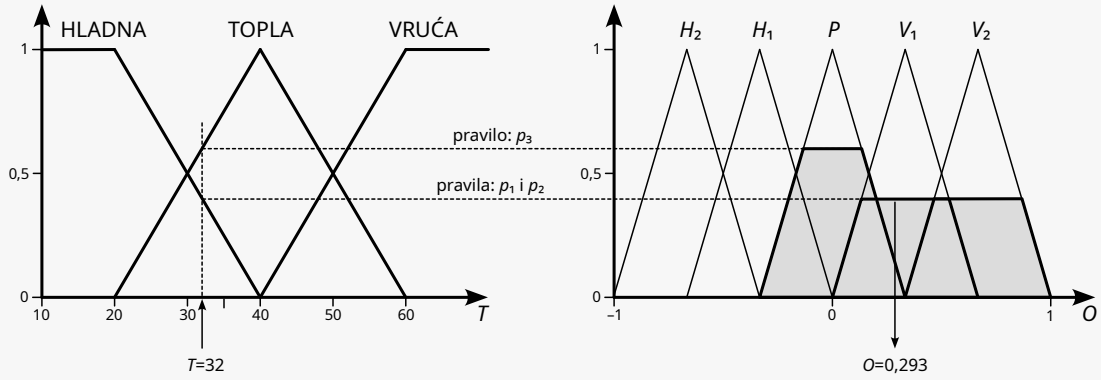

Slika 3.16.

Pravilo p_1 daje trapez na izlazu V_2 (donji dio trokuta V_2 do visine 0,4), pravilo p_2 trapeza na izlazu V_1 te pravilo p_3 trapez na izlazu P. Konačna površina na izlazu nastaje spajanjem pojedinačnih trapeza (zasivljeno područje). Trapezi se dijelom preklapaju, ali to ne smeta, ta se preklapajuća područja ne uzimaju s većom težinom ili tretiraju na drukčiji način – gleda se samo objedinjena površina.

Centroid površine (po izlaznoj varijabli O) je izlazna vrijednost sustava. Formalno se ona može prikazati integralom:

$$O = \frac{\int_{o_{min}}^{o_{max}} u \cdot \mathrm{f}(u)\,\mathrm{d}\,u}{\int_{o_{min}}^{o_{max}} \mathrm{f}(u)\,\mathrm{d}\,u} \tag{3.25.}$$

gdje su o_{min} i o_{max} granice centroida po O osi (horizontalnoj), a $\mathrm{f}(u)$ je funkcija gornje granice površine. Postupak se naziva *izračun izrazitih vrijednosti* (engl. *defuzzyfication*).

Umjesto integrala, s obzirom na to da se dobivena površina može rastaviti na trapez i paralelogram, svaki sa svojom površinom P_i i težištem t_i, ukupno težište se može jednostavnije izračunati prema:

$$O = \frac{\sum_i t_i \cdot P_i}{\sum_i P_i} \tag{3.26.}$$

Zadanom metodom izračunata izlazna vrijednost iznosi $O = 0,293$, što znači da će u omjeru tople/hladne biti više tople, što je i potrebno obzirom da je trenutna temperatura $T = 32$ °C manja od željene $T_P = 40$ °C.

Ovi primjeri (kao i svi navedeni u ovom priručniku) su navedeni s razlogom prikaza mogućnosti pojedinih postupaka, stoga i nisu detaljno razrađeni i analizirani (optimirani). Primjerice, ponašanje gornjeg upravljača u stvarnim sustavima bi možda bilo neprikladno jer nije napravljena analiza njegova rada niti u simuliranom okruženju gdje bi se mogla dobiti dinamička svojstva sustava. Npr. vrijeme se uopće nije razmatralo, a ono je neophodno radi podešavanja upravljanja u stvarnim sustavima. Zato nije dobro donositi neke općenite predodžbe kako treba izgledati upravljač zasnovan na neizrazitom zaključivanju samo na temelju navedenih primjera.

Problemi upravljanja koje smo susretali kod PID regulatora mogu biti prisutni i ovdje ako je upravljač loše projektiran. Primjerice, zbog neke vanjske smetnje možda upravljač ne bi mogao dovesti sustav u željeno stanje (kao i P regulator). Kada bi to bio slučaj onda bi trebalo ili drukčije postaviti ulazne skupove ili dodati neke u blizinu željenog stanja koji će imati snage dodatno gurnuti sustav prema željenom stanju. Uobičajeno se upravljači zasnovani na neizrazitom zaključivanju sastoje od više ulaznih skupova: pet, sedam ili i više, a ne samo tri kao u prikazanom primjeru.

Problem stabilnosti koji smo kod PID regulatora rješavali D komponentom se kod ovakvog upravljanja neizrazitom logikom često može rješiti samo dobrim postavkama ulaznih i izlaznih skupova. Kada to u nekim slučajevima ne bi bilo tako, mogli bi dodati pravila i skupove kojima bi rješavali samo taj problem.

Neizrazito upravljanje ima svojih prednosti i nedostataka. Najveće su mu prednosti u korištenju pravila koja su čovjeku razumljiva i koja bi on koristio u sličnim situacijama. Neki se složeni sustavi mogu relativno jednostavno upravljati korištenjem aproksimacije i heuristike. Osnovni problem može biti, kao i kod PID regulatora podešavanje parametara, pravila te postupaka zaključivanja (pretvorbe izrazito-neizrazito i obratno za izlazne vrijednosti).

Cjeloviti postupak upravljanja korištenjem neizrazitog zaključivanja može se prikazati slikom 3.17.

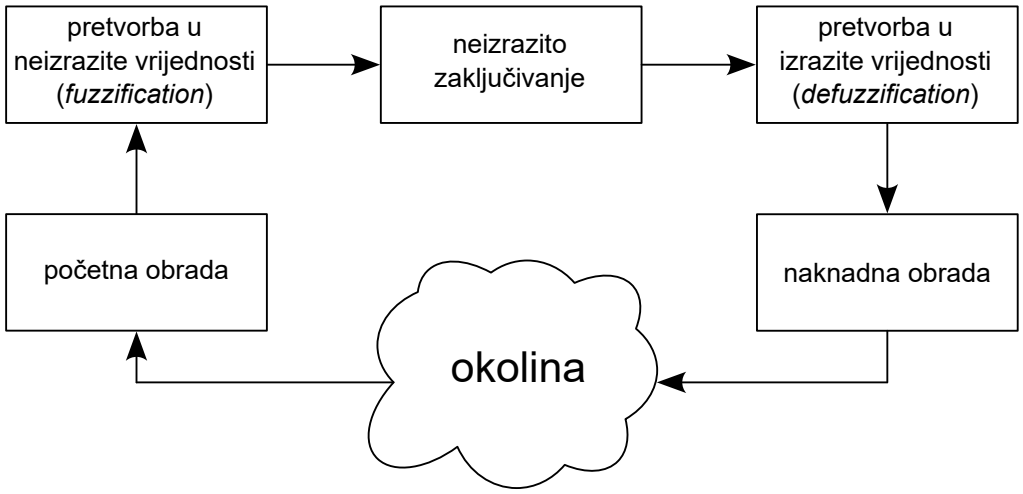

Slika 3.17. Upravljanje postupkom neizrazitog zaključivanja

Ponekad treba dodatno pripremiti (obraditi) ulazne vrijednosti, kao npr. izračunavanje odstupanja (na temelju kojeg se proračun obavlja), pretvorba jedinica, skaliranje i slično. Slični postupci mogu biti potrebni i na izlazu, u postupku naknadne obrade.

Projektiranje sustava pretpostavlja određivanje skupova za ulazne i izlazne vrijednosti, određivanje pravila zaključivanja te načina zaključivanja (npr. MIN_MAX postupak).

Upravljanje neizrazitom logikom je samo dotaknuto u ovim materijalima. Prije bilo kakvog korištenja ovog načina upravljanja potrebno ga je podrobnije proučiti, primjerice iz literature posvećene tom području.

Pitanja za vježbu 3

1. Struktura programa se odabire prema problemu koji se rješava. Navesti nekoliko uobičajenih struktura programa pogodnih za razne primjene u SRSV-ima te njihova svojstva.
2. Navesti prednosti i nedostatke sustava koji imaju samo prekidni podsustav i podsustav za upravljanje vremenom (trenutno vrijeme, alarmi) u kontekstu SRSV-a.
3. Koji elementi operacijskog sustava su potrebni pojedinim strukturama programa?
4. Zašto se svugdje ne koristi puni operacijski sustav sa svim svojim elementima (operacijama koje omogućuje za lakšu izradu programa)?
5. Što su to regulacijski zadaci?
6. Kod upravljanja kontinuiranih sustava radi se diskretizacija u vremenu. Kako odabrati korak diskretizacije?
7. Opisati upravljanje bez povratne veze i s povratnom vezom korištenjem formula.
8. Usporediti upravljanje bez povratne veze i upravljanje koje koristi povratnu vezu (prednosti, nedostaci, primjena).
9. Opisati uporabivost PID regulatora.
10. Od kojih se komponenata PID regulator sastoji?
11. Navesti uporabivost neizrazite logike u kontekstu upravljanja sustavima. Koja su dobra a koja loša svojstva neizrazite logike u tom okruženju?
12. Koja je posebna prednost korištenja neizrazitog upravljača (*fuzzy logic controller*) naspram ostalih oblika upravljanja?
13. Opisati postupak pretvaranja ulazne (izrazite) vrijednosti u neizrazitu (u sustavu upravljanja zasnovanom na neizrazitoj logici) (fuzzification).
14. Kako se koriste pravila zaključivanja (u sustavu upravljanja zasnovanom na neizrazitoj logici) korištenjem MIN_MAX postupka u dobivanju izrazite izlazne vrijednosti.
15. Za neki sustav koji je upravljan mikroupravljačem treba napraviti upravljački program za upravljanje dvaju procesa. Prvi treba obavljati svakih 37 ms (jednom u svakom intervalu od 37 ms) pozivom `obrada_1()`, a drugi svakih 47 ms (jednom u svakom intervalu od 47 ms) pozivom `obrada_2()`. Za mjerenje vremena na raspolaganju je 64-bitovno brojilo na adresi `BROJILO` koje odbrojava frekvencijom od 1 kHz (i za vrijeme rada sustava neće se premašiti najveća vrijednost koja stane u to brojilo). Obzirom na moguća dulja trajanja obrada (do 5 ms) paziti da se greška u vremenu ne povećava (da se periode ne povećavaju; preporuka koristiti “apsolutna vremena”)!

16. Neko računalo treba upravljati s nekoliko aktivnosti. Za aktivnost A treba jednom u 30 ms pozvati `a()`, za B treba jednom u 50 ms pozvati `b()` te za aktivnost C jednom u 100 ms pozvati `c()`. Jednom započeta obrada aktivnosti C (poziv `c()`) ne smije se prekidati (`a()` i `b()` se mogu prekidati). Aktivnost D treba aktivirati iz obrade prekida IRQ=39. Na raspolaganju stoji sučelje: `trenutno_vrijeme()` (vrijeme u milisekundama), `registriraj_prekid(irq, handler)`, `zabrani_prekidanje()`, `omogući_prekidanje()`. Napisati program za upravljanje (uz pretpostavku da funkcije `a()`, `b()`, `c()` i `d()` postoje), uključujući inicijalizaciju.

17. Prikazati (skicirati) ostvarenje upravljanja uređajem koji na ruci mjeri otkucaje srca, prikazuje trenutno stanje (često, barem svakih pola sekunde) te vibracijom dojavlja kada je broj otkucaja veći od N. Uređaj (ugrađeni sustav) posjeduje jednostavan mikrokontroler koji je opremljen i jednim 8-bitovnim brojilom koje odbrojava frekvencijom od 1 kHz (ali ne izaziva prekide). Posebnim se sklopom detektira otkucaj srca koji to tada dojavi procesoru prekidnim signalom. Ispis trenutnog pulsa (broja otkucaja u minuti) ispisati funkcijom `ispisi(int puls)` (funkcija postoji!). Vibracija (kratka) se aktivira pozivom funkcije `vibra()`.

18. Neko upravljačko računalo upravlja proizvodnim procesom. Upravljanje se sastoji od reakcije na vanjske događaje ("obradu prekida") te na periodičke akcije. Tri su izvora događaja P_1, P_2 i P_3 za koje se trebaju pozvati funkcije `p1()`, `p2()` i `p3()` (respektivno: za P_1 > `p1()`, itd.). Dvije su periodičke akcije: prvu `pera_1()` treba obavljati svakih 500 ms (jednom u 500 ms) te drugu `pera_2()` svakih 100 ms (prvi put u 0. ms a kasnije za svakih točno 100 ms ili što je moguće bliže tom trenutku). Riješiti problem upravljanja uz pretpostavku: a) (2) upravljačko računalo ima operacijski sustav (i sva sučelja koja uz to idu) te b) (3) upravljačko računalo nema operacijski sustav, tj. upravljanje ostvariti u upravljačkoj petlji (neka se pojave događaja očitavaju u adresama `ZP1`, `ZP2` i `ZP3` – jedinica označava pojavu)

19. PID regulator zadan je parametrima $K_P = 0,1$, $K_I = 0,3$, $K_D = 0,01$ te korakom integracije $T = 0,1$. Ako se reakcija okoline može simulirati formulom $y_{k+1} = y_k + 2 \cdot r_k$ napraviti dva koraka integracije (izračunati y_{k+1} i y_{k+2}). Trenutno stanje sustava je $y_k = 10$, a željeno stanje $y_P = 15$, uz $I_{k-1} = 2$ te $e_{k-1} = 1$.

20. Sustav koji je upravljan PID regulatorom u nekom je trenutku (koraku k) u stanju: $y_P = 100$ (željeno stanje), $y_k = 95$ (trenutno stanje), $e_{k-1} = 7$ (greška u prethodnom koraku) te $I_{k-1} = 5$ (suma grešaka do ovog koraka). Izračunati izlaz iz regulatora r_k, uz: $K_P = 0.5$, $K_I = 0.1$, $K_D = 0.05$ te $T = 0.1$ (T je korak u kojem regulator daje izlaz).

21. U sustavu u kojem se koristi neizrazito zaključivanje postoji pravilo:
p_1 : ako $(a \in A_1)$ ili $(b \in B_2)$ tada $(c \in C_3)$
Opisati primjenu tog pravila, ako se koristi MIN_MAX načelo.

22. Održavanje brzine treba ostvariti upravljačem zasnovanim na neizrazitu upravljanju. Pretpostaviti da su brzine s kojima sustav treba raditi u rangu 10-130 km/h, da motor (koji može i kočiti) može raditi s 7 različitih diskretnih snaga (-3, -2, -1, 0, 1, 2, 3). Pokazati rad projektiranog sustava (izračun jednog izlaza) ako je ulazna brzina 50 km/h a postavljena (željena) 80 km/h.

4. Raspoređivanje poslova

4.1. Uvod

Računalni sustavi koriste se za upravljanje nekim procesima (iz okoline) ili izvođenjem nekih korisniku potrebnih poslova (zadaća). Upravljanje s više poslova može se programski ostvariti na nekoliko načina, kao što je već i prikazano u prethodnom poglavlju. Ako se upravljanje može svesti na obradu događaja koje izazivaju vanjski procesi, tada se sva upravljačka logika može raspodijeliti u procedure koje obrađuju te događaje – u prekidne potprograme. Ako upravljanje traži periodičko očitanje stanja procesa te reakciju na očitanja, upravljanje se može ugraditi u obradu prekida sata ili izvesti programski, na način da se očitavaju svi upravljani procesi iz istoga kôda (periodičko "prozivanje").

Navedeni načini upravljanja pogodni su samo za jednostavnije sustave. U složenijim bi sustavima navedeni postupci postali suviše složeni, teško ostvarivi i vrlo teški za održavanje, otkrivanje grešaka, nadograđivanje i slično. Logika upravljanja koja se mora ugraditi u druge podsustave ili "zajedničke" upravljačke programe postaje suviše složena i glavni je problem ostvarenja takvih načina upravljanja.

Osnovni način rješavanja problem složenosti 'podijeli i vladaj' može se koristiti i za podjelu složenog upravljačkog programa u manje dijelove – *zadatke* (engl. *task*), od kojih se svaki zadatak brine za jedan vanjski proces. Upravljačka logika zasebnog zadatka je sva na jednom mjestu, samim time je i razumljivija što značajno olakšava i otkrivanje grešaka, ažuriranje i nadograđivanje. Dodavanje novih komponenti u sustav, kao i micanje nekih nepotrebnih, također je jednostavnije. Naravno, složenost sustava nije nestala već je "premještena" na druge razine – o tome kasnije. Primjer upravljačkog sustava ostvarenog višedretvenošću prikazuje slika 4.1.

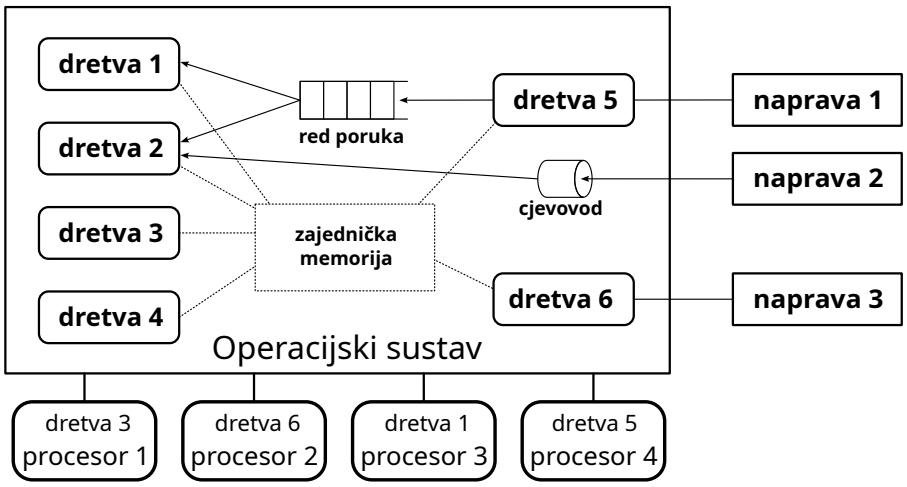

Slika 4.1. Primjer višedretvenog upravljačkog sustava

Odvajanje nezavisnih poslova upravljanja u zasebne zadatke – koji time postaju nezavisne jedinice izvođenja – *dretve*, samo je jedan od razloga potrebe za *višezadaćnim sustavom* (engl. *multitasking*), tj. *višedretvenim sustavom*. Najznačajnija korist višedretvenosti jest u učinkovitosti korištenja sustava. Naime, kad u sustavu postoji više dretvi, jedna dretva može čekati na dovršetak ulazno-izlazne (UI) operacije nad nekom napravom (koju je prije toga zadala – naprava "radi"), druga dretva može korisititi drugu napravu, treća procesor, četvrta drugi

procesor kada se radi o višeprocesorskom sustavu[1]. Dretvama upravlja operacijski sustav, koji osim raspoređivanja dretvi (odabira koje će se kada izvoditi na procesorima) omogućuje i dodatne mehanizme komunikacije i sinkronizacije, kao što su cjevovodi, redovi poruka, semafori i slično.

Potreba za višedretvenošću može proizlaziti i iz samo jednog posla. U takvom slučaju neki od mogućih razloga mogu biti:

- intenzivni računalni problemi koji se mogu rastaviti na (bar djelomično) neovisne dijelove (zadatke) mogu pomoću višedretvenosti bolje iskoristiti dostupne procesore;
- kada jedan posao zahtjeva proračune, ali i korištenje UI naprava, tada se elementi posla mogu odijeliti u one komponente koje vrše proračune i druge koje čekaju na UI naprave (primjerice u video igri neke dretve mogu biti specijalizirane za proračune fizike, mehanike i za grafički podsustav, a druge prihvaćaju ulaze korisnika, šalju i primaju pakete s mreže i slično);
- kada različite dretve upravljaju različitim elementima sustava koji traže različite načine upravljanja (npr. kontinuirani, periodički, sporadični poslovi, poslovi različita značaja i slično);
- kada je potrebno ostvariti asinkrono upravljanje događajima/zahtjevima (primjerice početna dretva Web poslužitelja svaki novi zahtjev stavlja u red koji obrađuju zasebne (radne) dretve tako da početna dretva može i dalje nesmetano prihvaćati nove zahtjeve bez obzira o trajanju obrade već pristiglih).

Osnovna ideja višedretvenosti jest u paralelnom radu više dretvi – stvarno paralelnom ili prividno paralelnom, korištenjem načela naizmjenična rada i podjele procesorskog vremena. Dretve mogu biti dio istog posla ili pak svaka raditi svoj posao. Operacijski sustav treba omogućiti dinamičko pokretanje poslova – stvaranje novih dretvi, bilo preko sučelja prema korisniku, bilo preko sučelja prema programima koji sami stvaraju dodatne dretve.

Stanje nekog sustava određuje skup dretvi koje se u njemu nalaze i koje obavljaju svoje poslove. Neke od dretvi mogu biti u stanju čekanja (blokirane/zaustavljene dretve), tj. prije nego što nastave s radom moraju pričekati na neki događaj (akciju druge dretve, vanjske naprave ili protok vremena). Primjerice, dretva može čekati na naredbu korisnika, dohvat podatka s diska, istek prethodno zadanog vremenskog intervala i slično. Ostale dretve su "pripravne" i mogu se izvoditi na procesoru.

Korisnik pokreće poslove/programe pri čemu operacijski sustav stvara dretve koje ih obavljaju. S korisničke strane to je dovoljno – korisnik u daljem radu treba pratiti rad programa i po potrebi upravljati njegovim radom (unositi tražene podatke, pokretati željene operacije i slično). Po dovršetku posla ili po naredbi korisnika program se zaustavlja – dotične dretve se zaustavljaju i miču iz sustava.

Zadaća operacijskog sustava jest da upravlja dretvama, da im daje procesorsko vrijeme kad im je potrebno i kad je njihov red u odnosu na ostale dretve, da ih miče "na stranu" kada ne trebaju procesorsko vrijeme (kad čekaju na nešto), da ih stvara i dodaje u sustav na zahtjev drugih dretvi i korisnika te da ih miče iz sustava pri završetku njihova rada.

U jednoprocesorskim sustavima u jednom trenutku može biti *aktivna* samo jedna dretva (izvoditi se na procesoru). Sve ostale moraju čekati da ta dretva završi ili da ju operacijski sustav makne s procesora. U sustavu s N procesora u istom trenutku može biti aktivno N dretvi. Način odabira aktivne dretve (ili N aktivnih) naziva se *raspoređivanje dretvi*.

[1] U ovom se tekstu pod pojmom višeprocesorskog sustava podrazumijeva svaki sustav koji ima više procesorskih jedinki, što obuhvaća i višestruke i mnogostruke procesore (engl. *multicore, manycore*).

Pojedina dretva može pripadati sustavu, obavljati potrebne operacije za sam sustav (primjerice obrada prekida, upravljanje ostalim zadacima i sredstvima sustava). Takvu dretvu nazivamo *dretvom sustava* ili *jezgrinom dretvom*. S druge strane dretva može pripadati nekom zadatku koji upravlja određenim vanjskim procesima, ili pak dretva može pripadati programu koji je korisnik pokrenuo, a koji za njega obavlja korisne operacije. Ovakve dretve nazivamo *korisničkim dretvama*.

Upravljanje dretvama treba omogućiti izvođenje svih dretvi u sustavu. Način i redoslijed izvođenja treba biti usklađen s važnošću posla koje dretve obavljaju. Korištenje sredstava sustava treba kontrolirati, ali i omogućiti njihovo korištenje od strane svih dretvi. U sredstva sustava spadaju: procesorsko vrijeme, spremnički prostor, UI naprave i ostala sredstva sustava, primjerice sinkronizacijski i drugi mehanizmi i objekti.

Upravljanje dretvama mora uzeti u obzir posebnosti pojedinih dretvi. U sustavima za rad u stvarnom vremenu dretve često imaju vremenske okvire u kojima trebaju napraviti zadani posao. Takva ograničenja treba uzeti u obzir prilikom upravljanja dretvama.

Problem raspoređivanja sredstava javlja se u gotovo svakom sustavu. Kako su gotovo svi sustavi upravljani računalima to postaje problem i u području računarstva. Raspoređivanje sredstava tako da se zadovolje sva ograničenja uz istovremeno postizanje očekivane učinkovitosti ili kvalitete može biti vrlo složen problem. U nastavku se razmatra samo problem *raspoređivanja dretvi*, odnosno raspoređivanje procesorskog vremena po dretvama sustava.

Raznolikost računalnih sustava zahtjeva razne postupke raspoređivanja te se iz istog razloga novi postupci neprestano istražuju i usavršavaju. Za različite probleme najčešće se koriste i različiti postupci raspoređivanja. Raspoređivač koji savršeno odgovara jednom tipu problema kod drugog može dati vrlo loše rezultate. Povećanje procesorske snage najčešće daje dovoljno dobre rezultate. Međutim, takvo rješenje poskupljuje gotovi proizvod te ga treba uzeti kao zadnje, ako se problem ne može riješiti drugim postupcima. Ponekad ni zamjena jačim računalom nije dovoljna.

Da bi se bolje razumjelo potrebe raznih sustava i načina raspoređivanja, u okviru ovog poglavlja detaljnije se prikazuju teoretske podloge raspoređivanja poslova, odnosno razmatra se raspoređivanje zadataka. U idućem, 5. poglavlju, prikazuju se načini raspoređivanja dretvi koji se zaista koriste u operacijskim sustavima.

4.2. Podjela poslova na zadatke

Određeni *posao* može se iz raznih razloga podijeliti na *zadatke*[2]. Jedan od značajnijih razloga podjele jest radi povećanja učinkovitosti na višeprocesorskim sustavima koji sve više prodiru u razne računalne sustave u koje svakako spadaju u SRSV-i.

Podjelu posla u zadatke može biti vrlo teško napraviti. Naime, najčešće nam je poznato kojim redoslijedom treba napraviti potrebne operacije da bi se dobio očekivani rezultat zadanog posla. Koje operacije mogu ići paralelno ili koje se operacije mogu razbiti na paralelne zadatke vrlo često nije jasno vidljivo.

Pri postupku podjele poslova u zadatke se često koriste grafičke metode, a da bi se tada vidjelo što ima smisla zaista odvojiti i izvoditi paralelno, a što ne. Česti način prikaza je usmjereni graf u kojemu su čvorovi zadaci dok usmjerene veze predstavljaju uređenje tj. potreban slijed izvođenja zadataka. Graf treba sadržavati samo zaista potrebne veze jer one ograničavaju paralelnost u radu, odnosno za svaku vezu će biti potrebno ugraditi sinkronizaciju između dva

[2]U engleskoj terminologiji za zadatak i posao se koriste termini *task* i *job*.

čvora koje veza povezuje.

Primjer 4.1. Primjer podjele posla na zadatke

Neka se posao P može početno podijeliti na skup slijednih zadataka $Z_1 \rightarrow Z_2 \rightarrow Z_3 \rightarrow Z_4 \rightarrow Z_5 \rightarrow Z_6$. U idućem koraku analize neka je ustanovljeno da zadatak Z_1 mora biti gotov prije pokretanja zadataka Z_2, Z_3 i Z_4, zadatak Z_5 mora čekati dovršetak Z_2 i Z_3 dok Z_6 zadatke Z_4 i Z_5. Navedene ovisnosti mogu se prikazati grafički prema slici 4.2.

Zadaci koji se mogu paralelno izvoditi su $\{Z_2; Z_3; Z_4\}$ te $\{Z_4; Z_5\}$. Ako su operacije koje rade navedeni zadaci složeniji, tj. dulje traju, ovakva podjela na zadatke (dretve u izvođenju) ima smisla i pridonijet će bržem završetku posla na višeprocesorskom sustavu. Ako je neki zadatak i sam jako složen, možda ima smisla i njega dodatno rastaviti na manje cjeline (podzadatke) koji se mogu dijelom paralelno izvoditi.

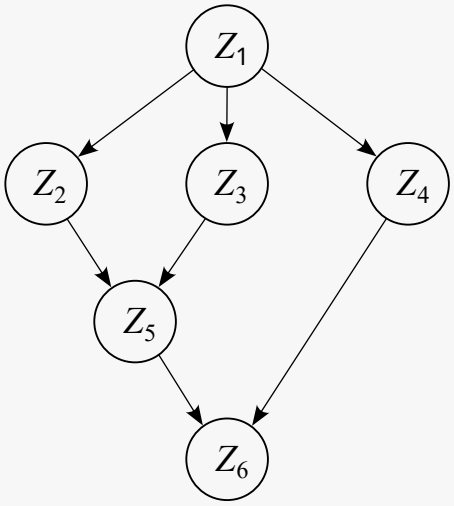

Slika 4.2. Međuovisnost zadataka prikazana grafom

Uobičajena podjela posla na zadatke sastoji se od početnog zadatka koji priprema okolinu (strukture podataka i slično) te pokreće N zadataka koji paralelno obavljaju dio posla. Po njihovu svršetku rezultati se prikupljaju i posao je gotov ili se sve ponavlja s drugim podacima. Slika 4.3. prikazuje takav rastav posla na zadatke.

Podjela posla na zadatke treba uzeti u obzir i arhitekturu višeprocesorskog sustava na kojem će se program izvoditi. Sa stanovišta učinkovitosti nije svejedno ima li sustav jedan procesor s više jezgri koje dijele priručni spremnik ili više procesora koji ne dijele priručne spremnike, ali dijele zajednički spremnik (engl. *symetric multiprocessor*) ili više procesora koji u grupama (čvorovima) dijele spremnik (engl. *non-uniform machine architecture*) ili se za proračune koriste posebni uređaji, primjerice procesori na grafičkim karticama.

Nadalje, treba uzeti u obzir dodatne operacije koje treba ugraditi u same zadatke radi sinkronizacije zadataka kao i za razmjenu podatka. Stoga treba vrlo dobro poznavati i rad operacijskog sustava te mehanizama sinkronizacije i komunikacije, tj. koliko one same mogu potrošiti procesorskog vremenena te je li se takva podjela uopće isplati. U nekim slučajevima to dodatno vrijeme (engl. *overhead*) može i premašiti vrijeme korisnog izvođenja te uzrokovati da višedretveni program (paralelni) bude sporiji od jednodretvenog (slijednog).

Međuovisnosti među zadacima istog posla treba pri programiranju ostvariti sinkronizacijskim

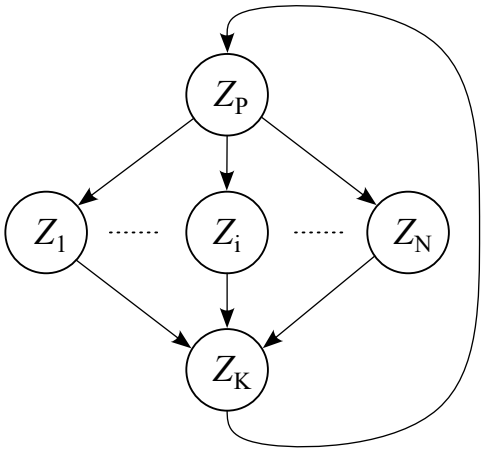

Slika 4.3. Uobičajena podjela posla na paralelne zadatke

mehanizmima. Više o sinkronizacijskim mehanizmima u 7. poglavlju. U nastavku, u razmatranju raspoređivanja zadataka privremeno će se zanemariti međuovisnost zadataka. Naime, u postupku raspoređivanja razmatraju se samo pripravnih zadaci, a to su zasigurno nezavisni zadaci jer su zavisni blokirani na sinkronizacijskom mehanizmu.

4.3. Vremenska svojstva zadataka

Zadaci mogu biti periodički s unaprijed zadanim vremenima ponavljanja ili sporadični, kao primjerice reakcija na pojavu prekida. I jedni i drugi zadaci imaju neka zajednička svojstva za čije se promatranje mogu definirati određeni vremenski trenuci bitni za njihovo odvijanje. Slika 4.4. prikazuje svojstvene trenutke pri obavljanju jednog zadatka.

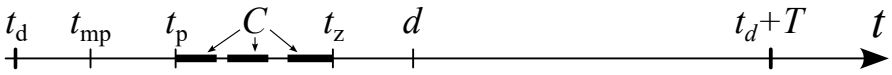

Legenda:

t_{d}	–	trenutak dolaska	C	–	trajanje obrade
t_{mp}	–	trenutak mogućeg početka	d	–	rok završetka
t_{p}	–	trenutak početka	T	–	period ponavljanja
t_{z}	–	trenutak završetka			

Slika 4.4. Svojstveni trenuci u životnom ciklusu jednog zadatka

Zadatak se pojavljuje u sustavu u trenutku t_{d} i da bi se obavio do kraja treba C jedinica procesorskog vremena (engl. *computation time, running time*). S obzirom na operacije koje obavlja može biti zahtjevano da svoj posao završi do roka d – krajnjeg trenutka završetka (engl. *deadline*). Ako zadatak ne završi do roka sustav snosi posljedice, stoga je vrlo bitno da se koristi raspoređivanje zadataka koje će svakom zadatku omogućiti završetak do svog roka. Radi pojedostavljenja u idućim razmatranjima promatraju se samo periodički zadaci te se za rok uzima trenutak idućeg pojavljivanja zadatka ($d = t_{\mathrm{d}} + T$) – ako nešto nije rasporedivo s ovakvim pojednostavljenjem očito neće biti ni bez njega.

Iz raznih razloga izvođenje zadatka ne može krenuti u samom trenutku pojave zadatka (npr. radi kućanskih poslova) već tek nakon nekog vremena. Neka trenutak kada izvođenje zadatka može započeti označimo s t_{mp} (koje može biti i jednako trenutku dolaska – uglavnom tako pretpostavljamo).

Trenutak kada raspoređivač odabere zadatak te kada on zaista započinje svoje izvođenje ozna-

čeno je s t_{p}. Dodatna odgoda može biti prouzrokovana dovršetkom prioritetnijih poslova.

Za vrijeme izvođenja zadatka on može biti i prekidan drugim zadacima većeg prioriteta ili obradama prekida.

U trenutku t_{z} zadatak završava s pridijeljenim poslom te nestaje iz sustava ili se privremeno zaustavlja do sljedećeg pojavljivanja (ako je zadatak periodički).

Ako je posao zadatka periodički, njegovo sljedeće aktiviranje očekuje se u trenutku $t_{\mathrm{d}} + T$ (T je period ponavljanja zadatka).

Vremenska uređenost događaja sa slike 4.4. mora se očuvati ako se želi ispravan rad sustava, tj. za navedene vremenske trenutke mora vrijediti uređenje (4.1.).

$$t_{\mathrm{d}} \leq t_{\mathrm{mp}} \leq t_{\mathrm{p}} < t_{\mathrm{z}} \leq d \tag{4.1.}$$

Zadaća operacijskog sustava, ili nekog drugog rješenja koje se koristi umjesto njega, jest omogućiti održavanje navedenog vremenskog uređenja za sve zadatke u sustavu. Drugim riječima, zadaci moraju biti upravljani tako da svoje izvođenje počinju najranije u trenutku t_{mp} te da sav posao obave najkasnije do d. Postoje razni postupci kako to postići, od kojih su neki vrlo jednostavni dok su drugi vrlo složeni. Odabir postupka ovisi o uporabi. Ponegdje će i oni najjednostavniji biti sasvim dovoljni dok će drugdje biti potrebni drugi, različite složenosti.

Za oznake perioda (T), potrebna procesorska vremena (C) te roka završetka (d) koriste se uobičajene kratice uglavnom engleskih naziva tako da formule u ovom poglavlju budu što sličnije onima u stranoj i znanstvenoj literaturi.

4.4. Postupci raspoređivanja

Postupci raspoređivanja zadataka (ili dretvi) određuju načine odabira zadataka i njihovo pridjeljivanje procesorima. Postoje mnogi postupci raspoređivanja zadataka, mnogi samo teoretski, ali i mnogi koji se koriste. Postupci se mogu podijeliti prema nekoliko kriterija od kojih su u nastavku podrobnije razmotrene sljedeće podjele:

- prema vremenu i načinu donošenja odluka raspoređivanja – prije pokretanja ili za vrijeme izvođenja
- prema postupanju sa zadacima u izvođenju – pušta ih se do kraja ili ih se može i prekinuti
- prema ciljnom računalnom sustavu – jednoprocesorskom, simetričnom i asimetričnom višeprocesorskom, spletu (engl. *cluster*), grozdu (engl. *grid*), ...

Poslovi koje izvode spletovi i grozdovi računala često su zahtjevni neinteraktivni proračunski poslovi. Takvim se računalima poslovi "šalju" posebnim naredbama (sučeljem). Raspoređivač poslova u takvim sustavima nastoji učinkovito iskoristiti procesorske mogućnosti, ali i ostala sredstva koja su kritična za takve poslove, posebice spremnički prostor. Stoga se takvi poslovi najčešće raspoređuju pojedinačno, tj. izvode se jedan po jedan od početka do kraja. Jedino u slučaju da jedan posao ne može iskoristiti svu dostupnu procesnu moć (ne posjeduje dovoljnu paralelnost – nema dovoljno dretvi), tada se može izvoditi više poslova. Ovakva raspoređivanja skupnih poslova (engl. *batch jobs*) neće se razmatrati u nastavku jer se za njihovo raspoređivanje koriste uobičajene metode optimiranja raspoređivanja sredstava.

4.4.1. Statički i dinamički postupci raspoređivanja

Prema trenutku donošenja odluke ili određivanju vrijednosti koje će se koristiti u postupku raspoređivanja, postupci se mogu podijeliti na:

- statičke i
- dinamičke.

4.4.1.1. Statički postupci raspoređivanja

Kod statičkih postupaka raspoređivanja odluke se donose prije pokretanja sustava (engl. *offline*). Sustav je najprije potrebno analizirati, donijeti odluke o raspoređivanju ili pridjeli obilježja zadacima koja će se koristiti pri raspoređivanju. Pridijeljena obilježja se ne mijenjaju tijekom rada kod statičkih postupaka raspoređivanja.

Odluke mogu biti predstavljene slijedom izvođenja zadataka: koji zadatak u kojem trenutku pokrenuti, kada zadatak zamijeniti drugim i slično, uvažavajući vremenska svojstva zadataka – kad se može koji zadatak pokrenuti te kada mora biti gotov. Slijed odluka može biti programiran u dodatni upravljački program koji će pokretati, zaustavljati i izmjenjivati zadatke na procesorima, npr. kao na primjeru 4.2. Postupak ugradnje odluka u raspoređivač jest vrlo učinkovit, ali i poprilično zahtjevan za ostvarenje. Naime, potrebno je jako dobro poznavati sve zadatke, njihova vremenska svojstva te na osnovu toga uobličiti upravljanje. Vrlo često takvi detaljni podaci nisu dostupni.

Drugi pristup statičkog raspoređivanja svodi se na utvrđivanju važnosti operacija koje obavljaju pojedini zadaci. Svakom se zadatku Z_i najprije definira prioritet u obliku broja. Raspoređivač pri donošenju svojih odluka uspoređuje zadatke Z_i i Z_j prema njihovim prioritetima p_i i p_j.

Primjer 4.2. Primjer statičkog raspoređivanja

Odluke raspoređivanja predstavljene su slijedom pokretanja zadataka:

```
...
ne radi ništa do t1
pokreni zadatak Z1
kad Z1 završi ne radi ništa do t2
pokreni Z2
ako je Z2 završio prije t3 tada
  pričekaj do t3
u t = t3:
  ako Z2 još nije gotov tada
    prekini i pohrani kontekst od Z2
  pokreni Z3
kada Z3 završi, nastavi sa Z2, ako nije bio gotov prije
ne radi ništa do t4
...
```

Raspoređivanje u takvom sustavu svodi se na odabir zadatka najvećeg prioriteta. Uobičajeno je da veća brojčana vrijednost predstavlja veći prioritet, ali ne mora biti tako. U nekim sustavima je obratno, manja brojčana vrijednost označava veći prioritet.

Zadaci se pokreću nezavisno, primjerice kao reakcija na događaje u sustavu (obrade vanjskih događaja mehanizmom prekida) ili periodički. U svakom takvom trenutku poziva se raspoređivač koji među svim pripravnim zadacima uzima onaj najvećeg prioriteta. Kada se u sustavu u nekom trenutku nađe više zadataka istog najvećeg prioriteta, odabir jednog od njih je ili proizvoljan ili se uvode dodatni kriteriji. Npr. ako se u sustavu nalaze tri zadatka s prioritetima $p_1 = 10$, $p_2 = 20$ te $p_3 = 20$, odabir između p_2 i p_3 je ili proizvoljan ili se može koristiti vrijeme kad su ti poslovi došli u red ili neki drugi dodatni kriterij.

Iako se samo raspoređivanje provodi za vrijeme izvođenja (engl. *online*), ovaj pristup se svrstava

u statičke jer su prioriteti statički pridjeljeni prije pokretanja sustava zadataka – zadaci ne mijenjaju svojstva koja se razmatraju pri raspoređivanju tijekom svog izvođenja.

Pridjeljivanje prioriteta zadataka te raspoređivanje prema prioritetu je jedno od najjednostavnijih načina raspoređivanja te se najčešće koristi u praksi (u operacijskim sustavima).

4.4.1.2. Dinamički postupci raspoređivanja

Suprotno statičkim postupcima, kod dinamičkih postupaka raspoređivanja svojstva zadataka koja se koriste pri raspoređivanju se mijenjaju tijekom vremena.

U notaciji prioriteta moglo bi se reći da se prioriteti zadataka mijenjaju vremenom i drugim događajima. Primjerice, dok je trenutak do kada neka operacija mora biti obavljena još daleko u budućnosti, prioritet pripadnog zadatka može biti mali. Kako vrijeme prolazi prioritet tog zadatka raste. Drugi primjer uključuje zadatak trenutno malog prioriteta (prema nekim dodatnim kriterijima), ali koji koristi određenu napravu. Kad se u sustavu pojavi zadatak visokog prioriteta koji treba tu istu napravu, ali koju se ne može prethodnom zadatku oduzeti dok se njegova operacija nad napravom ne obavi do kraja, prethodnom se zadatku može privremeno povisiti prioritet. Tako će zadatak početno manjeg prioriteta dobiti povećanje prioriteta koje će mu omogućiti da prije obavi svoje operacije nad napravom te po njenom oslobođenju omogući nastavak rada zadatka visokog prioriteta.

Dinamički postupci su u pravilu značajno složeniji od statičkih i zahtjevaju dodatne informacije o zadacima. Dinamički raspoređivači često i sami zahtjevaju nezanemarivo procesorsko vrijeme za izračun podataka na kojima se temelje njihove odluke – traže više "kućanskih poslova" od statičkih (imaju veći *overhead*) te se i znatno rjeđe koriste u stvarnim sustavima. Kada se koriste neki dinamički elementi zadataka onda se ipak odabiru postupci smanjene složenosti za raspoređivanja – teži se $O(1)$ ili u ponekad prihvatljivoj $O(\log n)$ složenošću.

Postupci raspoređivanja koji su primjenjivi na sustave zadataka u kojima neki zadaci ne mijenjaju parametre raspoređivanja (npr. prioritet) dok drugi zadaci mijenjaju (npr. prioritet raste protokom vremena) u nekim se literaturama nazivaju *mješovitim raspoređivanjem*.

4.4.2. Postupci raspoređivanja prilagođeni računalu

Postupak raspoređivanja koji je prilagođen jednoprocesorskim sustavima ne mora biti prikladan za višeprocesorske, i obratno. Nadalje, sami višeprocesorski sustavi mogu se podijeliti na simetrične, asimetrične, sa zajedničkim spremnikom, s raspodijeljenim spremnikom (prema procesorskim grupama) i slično (primjerice uvažavajući dijeljene priručne i lokalne djelove spremnika).

Optimalnost višeprocesorskog raspoređivanja je vrlo složena problematika te se, iako postoje mnoge studije na tu temu, ipak uzimaju jednostavniji suboptimalni postupci koji svoje odluke donose brzo.

Dodatni problemi kod višeprocesorskih raspoređivanja mogu nastati zbog istovremenog korištenja zajedničkih sredstava. Stoga i zadatke za takve sustave treba dodatno pripremiti ugradnjom potrebnih sinkronizacijskih i komunikacijskih mehanizama.

Iako su postupci raspoređivanja složeniji za višeprocesorske sustave te kod njih ima više kućanskih poslova i sinkronizacije, procesne mogućnosti takvi sustavi pružaju su vrlo često neophodni za ostvarenje upravljanja u SRSV-ima. Tome u prilog idu i noviji procesori koji su većinom višestruki (engl. *multicore*), čak i za ugrađene primjene.

U idućim poglavljima najprije se razmatra raspoređivanje za jednoprocesorska računala s obzi-

rom na to da je kod njih teže zadovoljiti vremenska ograničenja svih zadataka. Tek potom se razmatra raspoređivanje za višeprocesorska računala.

4.4.3. Prekidljivost zadataka

Postupci raspoređivanja mogu se podijeliti i prema kriteriju mogućnosti prekidanja zadataka u izvođenju na prekidljive (engl. *preemptive*) i neprekidljive (engl. *non-preemptive*). Naime, u nekim primjenama se jednom započeti zadatak ne smije prekidati dok ne završi sa svojim operacijama. Tek po završetku može se odabrati drugi. Drugi postupci dozvoljavaju prekidanje izvođenja zadataka radi obavljanja važnijih operacija, kao što su obrade prekida ili izvođenje zadataka većeg prioriteta.

Prednosti neprekidljivih postupaka jest u smanjenim kućanskim poslovima uzrokovanim spremanjem konteksta prekinutog zadatka i obnavljanjem konteksta novog posla koji prekida prethodni. Ipak, prednosti prekidljivih jesu u znatno bržem odzivu prema hitnim događajima i bitnijim zadacima. Stoga se uglavnom koriste postupci raspoređivanja koji pretpostavljaju prekidljive zadatke te će oni biti detaljnije razmatrani u nastavku.

I u sustavima s prekidljivima raspoređivačima može se ostvariti poneki neprekidljivi zadatak – dovoljno je da taj zadatak u željenom neprekidivom odsječku zabrani daljnja prekidanja te se ni sam raspoređivač neće moći pokrenuti dok mu sam zadatak to ponovno ne dozvoli. Taj se pristup koristi u SRSV-ima kod kojih postoje vrlo kritični zadaci čije su operacije bitnije od sveg ostalog (čak i od obrada prekida).

4.5. Jednoprocesorsko raspoređivanje

Sa stanovišta SRSV-a, osnovni problem kod jednoprocesorskog raspoređivanja jest kako zadatke rasporediti tako da se zadovolje vremenski zahtjevi svih zadataka (prema slici 4.4.), tj. kako ostvariti da sustav bude "rasporediv". Problem rasporedivosti je detaljnije analiziran u ovom odlomku.

4.5.1. Jednoprocesorsko statičko raspoređivanje

Statičko raspoređivanje zahtjeva analizu sustava zadataka prije pokretanja sustava. Statičko raspoređivanje koje će se razmatrati u nastavku ograničeno je na korištenje statički pridjeljenih prioriteta pojedinim zadacima, prema kriterijima postavljenim pri analizi sustava. Pitanje je kako pridijeliti prioritete zadacima, a da raspoređivanje bude zadovoljavajuće, barem za većinu slučajeva.

Radi jednostavnosti analize rasporedivosti, u nastavku se koriste pretpostavke prikazane definicijom 4.1.

Definicija 4.1. Početne pretpostavke za raspoređivanje zadataka

1. Razmatra se konačan skup (sustav) nezavisnih zadataka:

$$\mathcal{S} = \{Z_i = \{C_i, T_i\} \mid i \in \{1..N\}\} \tag{4.2.}$$

2. Svi zadaci su periodički – pojavljaju se u sustavu u trenucima $k \cdot T_i$, gdje je $k \in \mathbb{N}_0$ i T_i označava periodu zadatka Z_i.
3. Pojedina pojava zadatka Z_i u trenutku $k \cdot T_i$ se označava s z_i^k.

4. Zadatak z_i^k može započeti sa svojim izvođenjem odmah po pojavi.
5. U promatranom sustavu (s dostupnom brzinom procesora) izvođenje zadatka z_i^k u svakoj periodi ($\forall k$) traje jednako i iznosi C_i.
6. Rok za završetak rada zadatka z_i^k koji se pojavio u periodi k, u trenutku $k \cdot T_i$, je početak iduće periode: $d_i^k = (k+1) \cdot T_i$.
7. Zadatak z_i^k se može prekidati u svom izvođenju.
8. Sustav $\mathcal{S}$ je uređen tako da vrijedi: $T_1 < T_2 < \cdots < T_N$, tj. manje indekse imaju zadaci s kraćim periodama.

U definiciji 4.1. se pretpostavlja da svi zadaci imaju različite periode ponavljanja. To je potrebno u nekim idućim zaključivanjima. Kada to ne bi bilo tako, primjerice kada bi dva zadatka imala jednaku periodu, onda bi se jednom od njih (svejedno kojem) moglo dodati beskonačno malu vrijednost na periodu samo radi uređenja, da ih se može poredati znakom $<$.

Neka se prvo razmotre granični slučajevi – kada se sustav zadataka može rasporediti uz zadovoljenje vremenskih uvjeta, a kada ne.

4.5.1.1. Procesorska iskoristivost i izvodljivost raspoređivanja

Nikakav postupak raspoređivanja $\mathcal{R}$ neće moći posložiti poslove ako sustav ima previše posla – više nego što može obaviti. Kako provjeriti da li sustav ima previše posla?

Neka je zadan sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.). Svaki se zadatak Z_i iz $\mathcal{S}$ treba obaviti jednom unutar svake svoje periode. Unutar te periode zadatak Z_i treba C_i procesorskog vremena. Isto vrijedi za svaku periodu tog zadatka, odnosno on stvara opterećenje od C_i/T_i prema sustavu (procesoru). Slično je i s ostalim zadacima. Ukupno opterećenje, koje nazivamo i procesorskom iskoristivošću (engl. *utilization*), jest suma opterećenja pojedinih zadataka.

Definicija 4.2. Procesorska iskoristivost

Procesorska iskoristivost za sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.) računa se prema:

$$U_{\mathcal{S}} = \sum_{i=1}^{N} \frac{C_i}{T_i} \tag{4.3.}$$

Da bi sustav $\mathcal{S}$ mogao biti izvodljiv na zadanom procesoru, procesorska iskoristivost mora biti manja ili jedaka jedan, prema definiciji 4.3.

Definicija 4.3. Nužan uvjet rasporedivosti

Sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.) zadovoljava nužan uvjet rasporedivosti ako vrijedi:

$$U_{\mathcal{S}} \leq 1 \tag{4.4.}$$

Definicija 4.3. (formula 4.4.) vrijedi općenito, za sve postupke raspoređivanja na jednoprocesorskim sustavima. Međutim, pojedini postupak raspoređivanja može imati i dodatne uvjete na sustav zadataka, a da bi on bio rasporediv tim postupkom.

Najveći problem za raspoređivača će biti kada se svi zadaci iz $\mathcal{S}$ istovremeno pojave u sustavu, tj. kada se počeci njihovih perioda poklope. Tada se u sustavu nalazi najveći broj zadataka

koje procesor treba obaviti (prema redoslijedu koji određuje raspoređivač). Takav trenutak se naziva *kritični slučaj* i on se razmatra u postupku provjere rasporedivosti sustava zadataka (on se koristi u svim idućim postupcima).

Definicija 4.4. Kritični slučaj

Za sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.) definira se "kritični slučaj" kao trenutak kada se poklope počeci perioda svih zadataka.

4.5.1.2. Određivanje prioriteta zadataka

Statičko prioritetno raspoređivanje zahtijeva da zadaci imaju svoje prioritete. Kako dodijeliti prioritete pojedinima zadacima iz sustava $\mathcal{S}$, a da se raspoređivanjem prema prioritetu može rasporediti najviše takvih sustava? Prioritetni raspoređivač će u svakom trenutku odabrati zadatak najvećeg prioriteta, pa tako i u kritičnom slučaju. Primjer 4.3. prikazuje dva moguća načina dodjele prioriteta prema učestalosti pojave zadataka.

Primjer 4.3. Dodjela prioriteta prema učestalosti pojave

Zadan je sustav s dva zadatka $\mathcal{S} = \{Z_1, Z_2\}$. Neka se prvi zadatak javlja s $T_1 = 2$ s te neka njegovo računanje traje $C_1 = 1$ s. Drugi zadatak neka se javlja rijeđe, s $T_2 = 10$ s, ali traje dulje, $C_2 = 3$ s.

Provjerom nužnog uvjeta izvodljivosti raspoređivanja može se ustanoviti da je on zadovoljen:

$$U_{\mathcal{S}} = \sum_{i=1}^{N} \frac{C_i}{T_i} = \frac{1}{2} + \frac{3}{10} = 0,5 + 0,3 = 0,8 \leq 1$$

Nužan uvjet ne osigurava da je sustav rasporediv korištenjem prioritetnog raspoređivača.

Slika 4.5. prikazuje zadani sustav, periode ponavljanja i potrebna vremena u svakoj periodi.

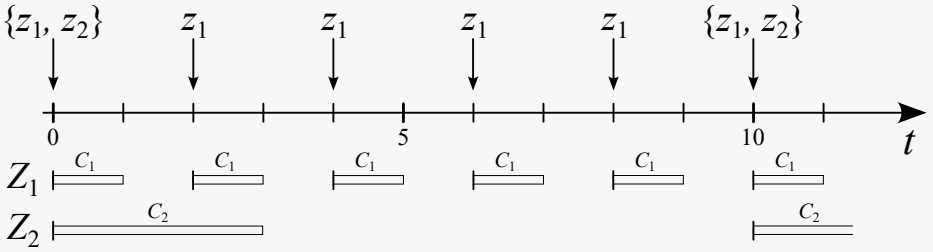

Slika 4.5. Sustav s dva zadatka

Prvi pokušaj dodjele prioriteta neka prioritete dodijeli prema frekvenciji pojavljivanja – zadatku koji se rjeđe javlja neka daje veći prioritet. Slika 4.6. prikazuje rad prioritetnog raspoređivača kod kojeg je zadatak Z_2 dobio veći prioritet.

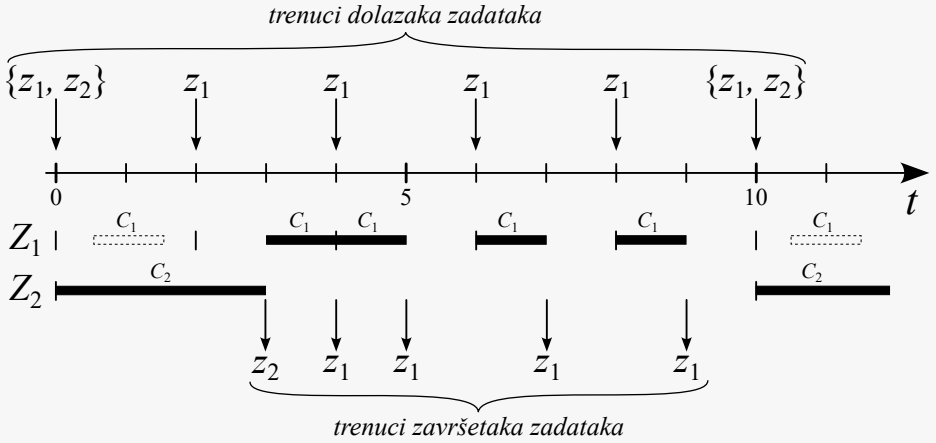

Slika 4.6. Veći prioritet zadacima koji se rijeđe pojavljuju

Iz slike je vidljivo da se prvo pojavljivanje zadatka Z_1 nije stiglo izvesti u dozvoljenim granicama.

Drugi način dodjele prioriteta je obrnuti: zadatku koji se češće javlja daje se veći prioritet. Slika 4.7. prikazuje rad raspoređivača u tom slučaju.

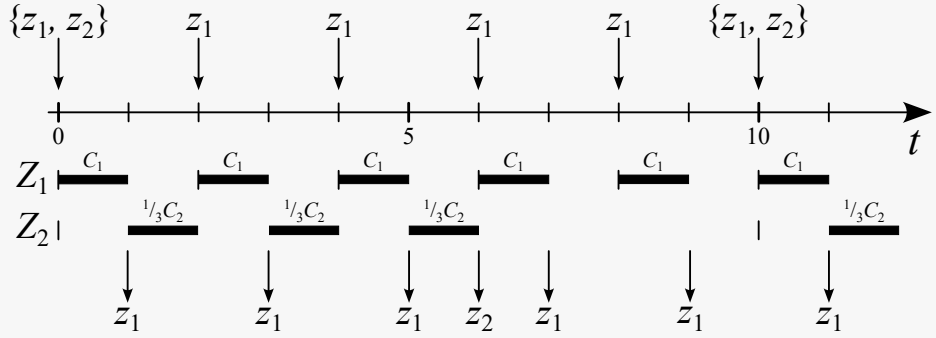

Slika 4.7. Veći prioritet zadacima koji se češće javljaju

Iz slike 4.7. je vidljivo da se izvođenje drugog zadatka prekida prvim, ali ipak i drugi zadatak stigne obaviti svoj posao prije svog roka, prije 10. jedinice vremena kada je kraj periode za taj zadatak.

Osim korištenja perioda zadataka za dodijelu prioriteta, kao što je to korišteno u primjeru 4.3., moglo bi se isprobati koristiti i trajanja. Primjerice, da zadatak s kraćim vremenom izvođenja dobiva veći prioritet. Treća je mogućnosti koristiti neku funkciju koja uzima i periode i trajanja.

Međutim, temeljita analiza svih ostalih načina napravljena u [Liu, 1973] pokazuje da je ipak duljina periode općenito najbolji odabir, tj. da zadacima koji imaju kraću periodu pojavljivanja – učestalije se javljaju, treba pridijeliti veći prioritet, a zadacima koji se rjeđe javljaju treba dati manji prioritet. Navedeni postupak pridjele prioriteta prema učestalosti pojavljivanja zadataka naziva se "mjera ponavljanja" (engl. *rate monotonic scheduling – RMS, rate monotonic priority assignment – RMPA*) i formalno je opisan definicijom 4.5.

Definicija 4.5. Dodjela prioriteta mjerom ponavljanja

Postupak pridjele prioriteta zadacima iz skupa $\mathcal{S}$ (prema definiciji 4.1.) korištenjem mjere

ponavljanja, zadacima $\{Z_1, Z_2, \ldots, Z_N\}$ će dodijeliti prioritete $\{p_1, p_2, \ldots, p_N\}$ (zadatku Z_1 prioritet p_1, zadatku Z_2 prioritet p_2, itd.) tako da vrijedi:

$$p_1 > p_2 > \ldots > p_N \tag{4.5.}$$

Zadacima s kraćom periodom postupak mjere ponavljanja dodjeljuje veći prioritet.

Raspoređivač koji raspoređuje prema prioritetu treba pozvati svaki put kada se nešto promijeni u sustavu, tj. kada se pojavi neki zadatak ili kada neki zadatak završi s radom. U svakom trenutku rada raspoređivač će među svim zadacima koji čekaju na obradu za aktivni zadatak odabrati zadatak najvećeg prioriteta.

Mjera ponavljanja (ili "raspoređivanje prema mjeri ponavljanja") je jedan od najjednostavnijih, ali i najčešće korištenih postupaka raspoređivanja u SRSV-ima.

4.5.1.3. Ograničenja pri raspoređivanju zadataka sa stalnim prioritetima

Raspoređivanje prema mjeri ponavljanja možda postavlja i dodatne uvjete na sustav zadataka, osim nužnog uvjeta prema definiciji 4.3. Prije detaljnije analize ograničenja slijedi nekoliko primjera grafičke provjere rasporedivosti sustava zadataka.

Definicija 4.6. Grafička provjera rasporedivosti

Sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.) bit će rasporediv odabranim postupkom raspoređivanja ako se grafičkom provjerom (simulacijom rada raspoređivača) u kritičnom slučaju potvrdi da su se svi zadaci koji su se pojavili u kritičnom slučaju $s = \{z_1^0, z_2^0, \ldots, z_N^0\}$ stigli obaviti do svojih trenutka kranjih završetaka (d_i) primjenom pravila postupka raspoređivanja, uzimajući u obzir i sve iduće pojave zadataka z_i^j koje se zbivaju za to vrijeme (dok se svi iz s ne obave).

Grafički postupak je vrlo jednostavan za ručnu provjeru, ali samo u kratkim primjerima koji se koriste u ovom prikazu. Nad većim sustavima, grafički postupak postaje značajno složeniji – uz graf bilo bi potrebno uvesti dodatne strukture za praćenje stanja svih zadataka.

Primjer 4.4. Grafička provjera rasporedivosti (1)

Zadan je sustav s tri zadatka s periodama i vremenima računanja prema:

$$\begin{aligned} Z_1: &\quad T_1 = 5 \text{ ms}, \quad C_1 = 2 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 5 \text{ ms} \\ Z_3: &\quad T_3 = 25 \text{ ms}, \quad C_3 = 5 \text{ ms} \end{aligned}$$

Provjera rasporedivosti:

a) Nužan uvjet

$$U = \sum_{i=1}^{3} \frac{C_i}{T_i} = \frac{2}{5} + \frac{5}{15} + \frac{5}{25} = 0,933 < 1$$

Nužan uvjet je zadovoljen.

b) Grafička provjera u kritičnom slučaju

Slika 4.8. prikazuje grafički postupak provjere rasporedivosti.

Prioritetni raspoređivač uvijek odabire zadatak najvećeg prioriteta. Prema postupku mjere ponavljanja zadatak Z_1 ima najveći prioritet s obzirom na to da ima najkraću periodu.

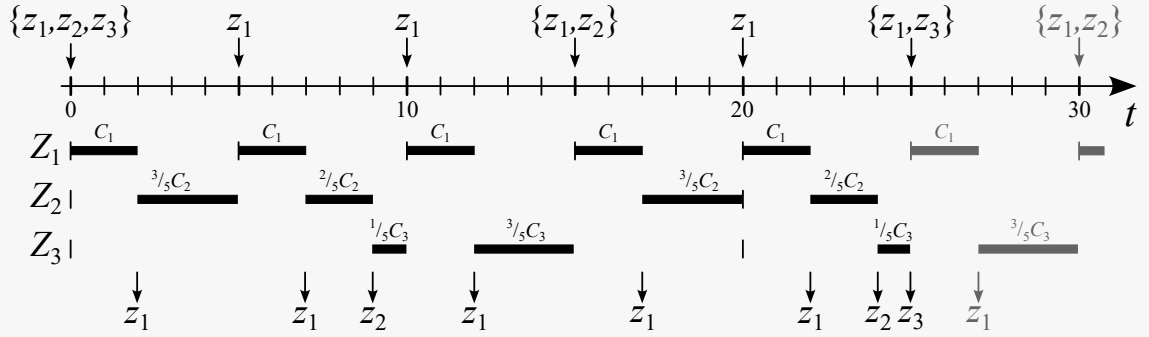

Slika 4.8.

Provjera će općenito najkasnije završiti na kraju periode najmanje prioritetnog zadatka. Najčešće je taj zadatak najmanjeg prioriteta najproblematičniji što se raspoređivanja tiče jer ga svi novi prekidaju. Međutim, provjeru treba obaviti za sve zadatke koji se do tada javljaju (i imaju veći prioritet). Provjera može završiti i ranije, u trenutku završetka zadatka najmanjeg prioriteta.

Iz slike je vidljivo da svoje izvođenje prije početka svojeg idućeg perioda završavaju svi zadaci, ne samo oni koji se javljaju u $t = 0$ (kritičnom slučaju) već i svi ostali koji se javljaju u intervalu do $t = 25$. Najkritičniji u ovom sustavu je zadatak Z_3 koji taman završava u $t = 25$ kad se isti zadatak opet javlja.

Zaključak: sustav je rasporediv prema postupku mjere ponavljanja.

Na grafu je vidljivo da je procesor zauzet sve do 25. jedinice vremena što na prvi pogled može zbuniti obzirom da je izračunata iskoristivost manja od jedan. Međutim, promatranjem simulacije duže u budućnosti, u najgorem slučaju do idućeg kritičnog slučaja, trebali bi pronaći intervale u kojima je procesor slobodan.

Primjer 4.5. Grafička provjera rasporedivosti (2)

Zadan je sustav s tri zadatka s periodama i vremenima računanja prema:

$$\begin{aligned} Z_1: &\quad T_1 = 10 \text{ ms}, \quad C_1 = 5 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 5 \text{ ms} \\ Z_3: &\quad T_3 = 20 \text{ ms}, \quad C_3 = 1 \text{ ms} \end{aligned}$$

Provjera rasporedivosti:

a) Nužan uvjet

$$U = \sum_{i=1}^{3} \frac{C_i}{T_i} = \frac{5}{10} + \frac{5}{15} + \frac{1}{20} = 0,883 < 1$$

Nužan uvjet je zadovoljen.

b) Grafička provjera u kritičnom slučaju

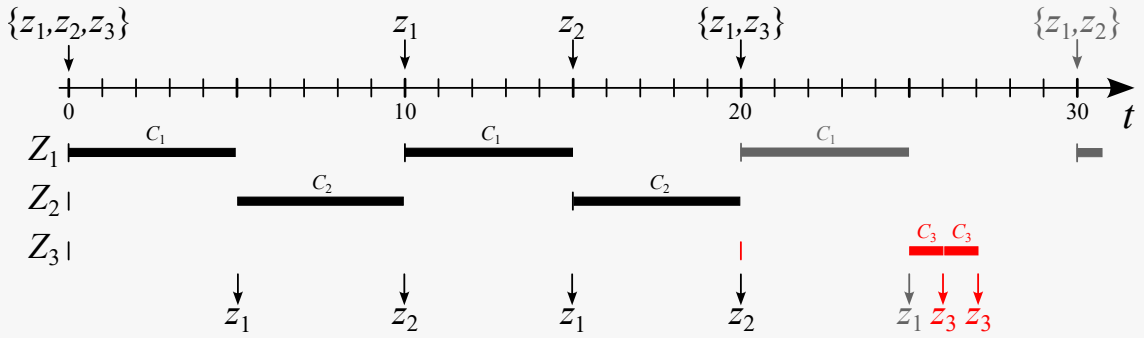

Slika 4.9.

Iz slike 4.9. je vidljivo da zadatak Z_3 ne stigne obaviti svoje prvo pojavljivanje u $t = 0$ do svojeg idućeg pojavljivanja u $t = 20$. Time nije ispunjen uvjet dovršetka do svog roka te samim time sustav zadataka nije rasporediv prema postupku mjere ponavljanja. Otkriće da neki zadatak ne stiže obaviti svoje operacije do zadanih ograničenja zaustavlja provjere – ograničenja su narušena te sustav sigurno nije rasporediv.

Kada bi za Z_3 dopustili prekoračenje roka za npr. 10 jedinica vremena, onda vidimo da bi obje pojave zadatka Z_3 mogle biti obavljene nakon 25. ms, kada je procesor slobodan. Na slici 4.9. je taj dio prikazan crveno, nije dio provjere raspoređivosti – on staje u 20. ms negativnim odgovorom, čim je detektirano prekoračenje.

Zaključak: sustav nije rasporediv prema postupku mjere ponavljanja.

Svaki periodički zadatak Z_i (prema definiciji 4.1.) ima zadan svoj (eksplicitni) rok d_i^k u svakoj svojoj pojavi kao trenutak iduće pojave istog zadatka. Međutim, možda on mora završiti i prije ako u tom trenutku ili neposredno prije $((k+1) \cdot T_i)$ procesor izvodi zadatak većeg prioriteta.

Definicija 4.7. Implicitni rok – ID_i

Za zadatak Z_i iz sustava zadataka $\mathcal{S}$ (prema definiciji 4.1.) definira se *implicitni rok* ID_i (engl. *implicit deadline*) kao trenutak u kojem zadatak mora završiti, računajući od pojave tog zadatka u kritičnom slučaju (za $t = 0$, za pojavu z_i^0).

ID_i može biti jednak $d_i = T_i$, ali može biti i manji ako je vrijeme od ID_i do T_i popunjeno obradama prioritetnijih zadataka.

Kada je zadatak Z_i rasporediv, tada je ID_i ili jednak periodi ponavljanja zadatka T_i ili je manji.

Kada je ID_i manji od T_i, tada on može biti jedino jednak trenutku ponovne pojave nekog od prioritetnijih zadataka Z_j $(j < i)$ u intervalu $\langle 0, T_i \rangle$. Takvi priritetniji zadaci u potpunosti koriste interval $\langle ID_i, T_i \rangle$ i ne ostavljaju prostora (vremena) za zadatak Z_i.

ID_i se traži među točkama raspoređivanja zadatka Z_i.

Definicija 4.8. Točke raspoređivanja D_i

U kontekstu razmatranja raspoređivosti sustava zadataka zadanog prema definiciji 4.1. promatranog u kritičnom slučaju, *točke raspoređivanja* D_i za zadatak Z_i su trenuci idućih

pojava zadataka iz skupa $\{Z_1, Z_2, \ldots, Z_i\}$ (prioritetniji zadaci od Z_i uz sam Z_i) u intervalu $\langle 0, T_i \rangle$ (pojave z_j^p uz $j \leq i$, $p > 0$ te $0 < p \cdot T_j \leq T_i$).

Slika 4.10. prikazuje odnos D_i u odnosu na početak i kraj periode zadatka Z_i za $D_i < T_i$.

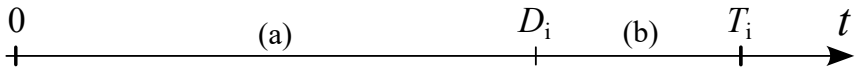

Slika 4.10. D_i **– implicitni** d_i

Zadatak Z_i u svom prvom pojavljivanju u kritičnom slučaju stići će obaviti svoj posao do D_i ako se od početka periode, tj. od pojave zadatka do D_i (u intervalu (a) sa slike 4.10.) stignu obaviti svi prioritetniji zadaci i to onoliko puta koliko se javljaju u tom intervalu te uz to ostane dovoljno vremena da se i zadatak Z_i obavi do kraja.

Definicija 4.9. Opći kriterij rasporedivosti

Sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.) bit će raspored postupkom mjere ponavljanja ako za svaki zadatak Z_i iz skupa $\mathcal{S}$ postoji $D_i \in [0, T_i]$ koji u kritičnom slučaju zadovoljava uvjet:

$$(a): \quad \sum_{j=1}^{i} \left\lceil \frac{D_i}{T_j} \right\rceil \cdot C_j \leq D_i \tag{4.6.}$$

D_i se odabire među točkama raspoređivanja zadatka Z_i (prema definiciji 4.8.). Operator $\lceil x \rceil$ vraća prvi cijeli broj jednak ili veći od x.

Numerički postupak određivanja rasporedivosti zadatka Z_i svodi se na pronalazak jednog trenutka D_i među točkama rasporedivosti za koji je zadovoljena nejednakost (4.6.).

Da bi D_i prema definiciji 4.7. zaista bio i implicitni rok ID_i, tada interval $\langle D_i, T_i \rangle$, na slici 4.10. označen s (b), mora biti popunjen obradom prioritetnijih zadataka.

Prioritetniji zadatak Z_j se u intervalu T_i javlja $\lceil T_i/T_j \rceil$ puta i toliko će se puta obraditi i istisnuti Z_i, prvi put na početku periode, a potom nakon svake pojave unutar periode.

U intervalu od pojave zadatka Z_i do D_i ($[0, D_i]$, na slici 4.10. dio označen s (a)) zadatak Z_j javlja se $\lceil D_i/T_j \rceil$ puta. U intervalu od D_i do kraja periode (i) zadatak Z_j se javlja $\lceil T_i/T_j \rceil - \lceil D_i/T_j \rceil$ puta. Navedeni izraz uzima u obzir da se prvo pojavljivanje zadatka Z_j poklapa s početkom periode. Sličan izraz $\lceil (T_i - D_i)/T_j \rceil$ to ne uzima u obzir i nije uvijek ispravan te se ne koristi.

Vrijeme potrošeno na zadatke većeg prioriteta koji se javljaju u intervalu od D_i do kraja periode, tj. u $\langle D_i, T_i \rangle$ prikazano je formulom (4.7.).

$$\sum_{j=1}^{i-1} \left(\left\lceil \frac{T_i}{T_j} \right\rceil - \left\lceil \frac{D_i}{T_j} \right\rceil \right) \cdot C_j \tag{4.7.}$$

Treba primjetiti da formula (4.7.) ne uzima u obzir zadatke koji su započeli prije D_i, ali nastavljaju sa svojim izvođenjem nakon D_i. Međutim, takvi zadaci su već uzeti u obzir nejednakošću (4.6.) koja mora biti ispunjena, a da bi D_i bio kandidat za implicitni rok, tj. takvi zadaci završavaju prije D_i (nejednakost (4.6.) to zahtjeva).

Da bi svo vrijeme od D_i do kraja periode bilo popunjeno prioritetnijim zadacima, vrijednost prema formuli (4.7.) mora biti veće ili jednako intervalu $\langle D_i, T_i \rangle$ na slici 4.10. označenome s (b).

Definicija 4.10. Određivanje implicitna roka

Za zadatak Z_i iz sustava zadataka $\mathcal{S}$ (prema definiciji 4.1.), vrijednost D_i jest implicitni rok ID_i ako je to najmanja vrijednost koja zadovoljava uvjet (a) iz definicije 4.9. te uvjet (b) prema formuli (4.8.).

$$(b): \quad \sum_{j=1}^{i-1} \left(\left\lceil \frac{T_i}{T_j} \right\rceil - \left\lceil \frac{D_i}{T_j} \right\rceil \right) \cdot C_j \geq T_i - D_i \tag{4.8.}$$

Uvjet (b) iz definicije 4.10. provjerava da li u intervalu $\langle D_i, T_i \rangle$ ima slobodnog procesorskog vremena za završetak zadatka Z_i ili se svo procesorsko vrijeme u tom intervalu troši na zadatke većeg prioriteta.

Primjer 4.6.

Razmotrimo jednostavni primjer s dva zadatka $\{Z_1, Z_2\}$ koji se javljaju svakih $T_1 = 7$ te svakih $T_2 = 10$ jedinica vremena. Neka su trajanja računanja $C_1 = 3$ te $C_2 = 1$.

Pri razmatranju rasporedivosti zadatka Z_1 jedina točka raspoređivanja koja je kandidat za D_1 je $D_1 = T_1$. U njoj su zadovoljena oba uvjeta iz definicija 4.9. i 4.10.

$$(a): \quad C_1 \leq T_1$$
$$(b): \quad 0 \geq T_1 - T_1$$

Pri razmatranju rasporedivosti zadatka Z_2 točke raspoređivanja su: $D_2 \in \{T_1, T_2\}$ te se uvjeti provjeravaju prema:

$$(a): \quad \left\lceil \frac{D_2}{T_1} \right\rceil \cdot C_1 + \left\lceil \frac{D_2}{T_2} \right\rceil \cdot C_2 \overset{?}{\leq} D_2$$
$$(b): \quad \left(\left\lceil \frac{T_2}{T_1} \right\rceil - \left\lceil \frac{D_2}{T_1} \right\rceil \right) \cdot C_1 \overset{?}{\geq} T_2 - D_2$$

Za $D_2 = T_1 = 7$ uvrštavanjem se dobiva:

$$(a): \quad 1 \cdot 3 + 1 \cdot 1 \overset{?}{\leq} 7 \quad \checkmark$$
$$(b): \quad (2-1) \cdot 3 \overset{?}{\geq} 3 \quad \checkmark$$

Oba su uvjeta zadovoljena, iz čega slijedi da je zadatak rasporediv, pa tako i sustav, s obzirom na to da je i prvi zadatak rasporediv.

Što se dobiva kad bi se uzelo drugu vrijednost za D_2, tj. $D_2 = T_2 = 10$?

$$(a): \quad 2 \cdot 3 + 1 \cdot 1 \overset{?}{\leq} 10 \quad \checkmark$$
$$(b): \quad (2-2) \cdot 3 \overset{?}{\geq} 0 \quad \checkmark$$

Opet su oba uvjeta zadovoljena. U ovom primjeru se potvrda rasporedivosti dobiva odabirom bilo koje vrijednosti za D_2.

Prema definiciji 4.7. implicitni d_i je trenutak kada zadatak *može* završiti. S obzirom na to da za ovaj primjer vrijeme od 7. do 10. jedinice vremena troši zadatak Z_1, očito je da implicitni rok nije $T_2 = 10$, zadatak Z_2 se ne može ni izvoditi ni završiti u tom intervalu (provjera uvjeta (b) za $D_2 = 7$ je to potvrdila). Preostaje prva točka raspoređivanja $D_2 = T_1 = 7$ kada doista zadatak Z_2 može završiti s obzirom na to da je prije toga je procesor slobodan (Z_1 koristi interval $[0, 3]$ te je interval $[3, 7]$ slobodan za Z_2).

Kada se radi samo provjera rasporedivosti sustava zadataka dovoljno je koristiti definiciju 4.9. (nije potrebno dodatno pronalaziti i ID_i).

Iz primjera 4.6. mogao bi se steći dojam da je dovoljno za D_i uzeti vrijednost T_i. Pri provjeri rasporedivosti općim kriterijem često je najbolje krenuti s tom vrijednošću. Ali ako provjera za nju ne daje pozitivan odgovor, ne smije se još donositi i zaključak o rasporedivosti sustava zadataka već treba ispitivanje ponoviti u ostalim točkama raspoređivanja. Primjerice, kada bi u primjeru 4.6. trajanja bila $C_1 = 4$ i $C_2 = 2$ tada uvjet (a) u $D_2 = T_2 = 10$ neće biti zadovoljen, dok će za $D_2 = 7$ uvjet i dalje biti zadovoljen.

Primjer 4.7.

Prikažimo korištenje općeg kriterija rasporedivosti na istom sustavu kao i u primjeru 4.4.:

$$\begin{aligned} Z_1: &\quad T_1 = 5 \text{ ms}, \quad C_1 = 2 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 5 \text{ ms} \\ Z_3: &\quad T_3 = 25 \text{ ms}, \quad C_3 = 5 \text{ ms} \end{aligned}$$

a) Rasporedivost zadatka Z_1

Za prvi, najprioritetniji zadatak Z_1 jedina točka raspoređivanja je iduće pojavljivanje tog istog zadatka, tj. provjera se obavlja za $D_1 = 5$ ms.

$$(a): \quad \left\lceil \frac{D_1}{T_1} \right\rceil \cdot C_1 \overset{?}{\leq} D_1 \quad \Rightarrow \quad \left\lceil \frac{5}{5} \right\rceil \cdot 2 \overset{?}{\leq} 5 \quad \checkmark$$

Zaključak: prvi je zadatak rasporediv.

b) Rasporedivost zadatka Z_2

Za drugi zadatak Z_2 točke raspoređivanja su: $D_2 \in \{5, 10, 15\}$ ms.

Provjera za vrijednost $D_2 = 5$ ms:

$$(a): \quad \left(\left\lceil \frac{D_2}{T_1} \right\rceil \cdot C_1 + \left\lceil \frac{D_2}{T_2} \right\rceil \cdot C_2 \right) \overset{?}{\leq} D_2 \quad \Rightarrow \quad \left(\left\lceil \frac{5}{5} \right\rceil \cdot 2 + \left\lceil \frac{5}{10} \right\rceil \cdot 5 \right) \overset{?}{\leq} 5 \quad \text{✗}$$

Za prvu vrijednost $D_2 = 5$ prvi uvjet nije zadovoljen, tj. do 5. ms nema vremena za obavljanje prva dva zadatka.

Provjera za vrijednost $D_2 = 10$ ms:

$$(a): \left(\left\lceil \frac{10}{5} \right\rceil \cdot 2 + \left\lceil \frac{10}{10} \right\rceil \cdot 5 \right) \overset{?}{\leq} 10 \quad \checkmark$$

Uvjet (a) je zadovoljen, zadatak Z_2 je rasporediv.

c) Rasporedivost zadatka Z_3

Za treći zadatak Z_3 točke raspoređivanja su: $D_3 \in \{5, 10, 15, 20, 25\}$ ms. Istim postupkom mogli bi provjeriti za sve točke raspoređivanja. U nastavku je dano rješenje samo za zadnju točku raspoređivanje, tj. za $D_3 = 25$ ms (u ostalim točkama zadatak nije rasporediv).

$$(a): \quad \left\lceil \frac{D_3}{T_1} \right\rceil \cdot C_1 + \left\lceil \frac{D_3}{T_2} \right\rceil \cdot C_2 + \left\lceil \frac{D_3}{T_3} \right\rceil \cdot C_3 \overset{?}{\leq} D_3 \quad \Rightarrow \quad \left\lceil \frac{25}{5} \right\rceil \cdot 2 + \left\lceil \frac{25}{15} \right\rceil \cdot 5 + \left\lceil \frac{25}{25} \right\rceil \cdot 5 \overset{?}{\leq} 25 \quad \checkmark$$

Zaključak: treći je zadatak rasporediv.

Sva tri zadatka su rasporediva te je prema tome i sustav zadataka rasporediv.

Istim postupkom bi se mogao provjeriti i sustav iz primjera 4.5. Rezultat bi trebao pokazati da iako su prva dva zadatka rasporediva, treći nije rasporediv niti u jednoj točki raspoređivanja. U nastavku je ipak prikazan primjer s novim sustavom zadataka.

Primjer 4.8.

Zadan je sustav sa četiri zadatka s periodama i vremenima računanja prema:

$$\begin{aligned} Z_1: &\quad T_1 = 5 \text{ ms}, \quad C_1 = 1 \text{ ms} \\ Z_2: &\quad T_2 = 8 \text{ ms}, \quad C_2 = 1 \text{ ms} \\ Z_3: &\quad T_3 = 9 \text{ ms}, \quad C_3 = 2 \text{ ms} \\ Z_4: &\quad T_4 = 10 \text{ ms}, \quad C_3 = 3 \text{ ms} \end{aligned}$$

Provjera rasporedivosti:

a) Nužan uvjet

$$U = \sum_{i=1}^{4} \frac{C_i}{T_i} = \frac{1}{5} + \frac{1}{8} + \frac{2}{9} + \frac{3}{10} = 0,847 < 1 \qquad \checkmark$$

Nužan uvjet je zadovoljen. Provedimo i grafičku provjeru (za razliku od općeg kriterija, grafička provjera je vrlo brza za male sustave zadataka).

b) Grafička provjera u kritičnom slučaju

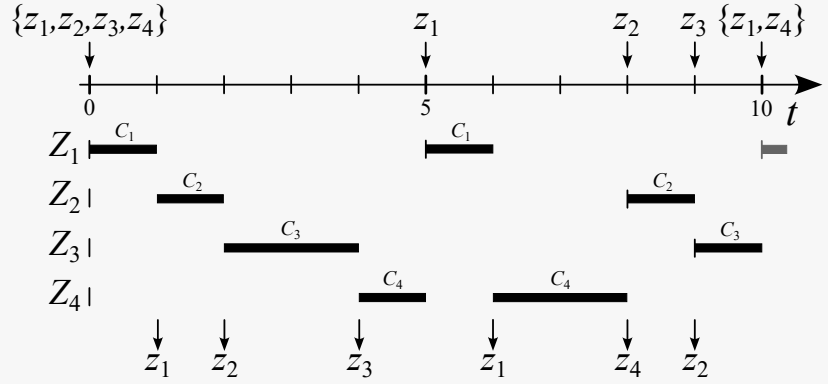

Slika 4.11.

Grafička provjera daje potvrdan odgovor o rasporedivosti (postupkom mjere ponavljanja). Općim kriterijom bit će provjeren samo četvrti zadatak.

Za četvrti zadatak Z_4 točke raspoređivanja su: $D_4 \in \{5, 8, 9, 10\}$ ms.

Iz slike 4.11. je vidljivo da bi provjere za $D_4 \in \{5, 9, 10\}$ bile neuspješne, odnosno $D_4 = 8$ je prava vrijednost implicitnog d_4. Prikažimo to i preko općeg kriterija i definicije 4.10.

Uvjet (a):

$$(a): \left\lceil \frac{D_4}{T_1} \right\rceil \cdot C_1 + \left\lceil \frac{D_4}{T_2} \right\rceil \cdot C_2 + \left\lceil \frac{D_4}{T_3} \right\rceil \cdot C_3 + \left\lceil \frac{D_4}{T_4} \right\rceil \cdot C_4 \stackrel{?}{\leq} D_4$$

Uvrštavanjem:

$$(a): \left\lceil \frac{8}{5} \right\rceil \cdot 1 + \left\lceil \frac{8}{8} \right\rceil \cdot 1 + \left\lceil \frac{8}{9} \right\rceil \cdot 2 + \left\lceil \frac{8}{10} \right\rceil \cdot 3 \stackrel{?}{\leq} 8 \quad \checkmark$$

Uvjet (b):

$$(b): \left(\left\lceil \frac{T_4}{T_1} \right\rceil - \left\lceil \frac{D_4}{T_1} \right\rceil \right) \cdot C_1 + \left(\left\lceil \frac{T_4}{T_2} \right\rceil - \left\lceil \frac{D_4}{T_2} \right\rceil \right) \cdot C_2 + \left(\left\lceil \frac{T_4}{T_3} \right\rceil - \left\lceil \frac{D_4}{T_3} \right\rceil \right) \cdot C_3 \stackrel{?}{\geq} T_4 - D_4$$

Uvrštavanjem:

$$(b): \left(\left\lceil \frac{10}{5} \right\rceil - \left\lceil \frac{8}{5} \right\rceil \right) \cdot 1 + \left(\left\lceil \frac{10}{8} \right\rceil - \left\lceil \frac{8}{8} \right\rceil \right) \cdot 1 + \left(\left\lceil \frac{10}{9} \right\rceil - \left\lceil \frac{8}{9} \right\rceil \right) \cdot 2 \stackrel{?}{\geq} 10 - 8 \quad \checkmark$$

Očekivani zaključak: zadatak Z_4 je rasporediv.

4.5.1.4. Granice procesorske iskoristivosti

Procesorska iskoristivost može se koristiti kao mjera opterećenja ali i za procjenu rasporedivosti sustava.

Definicija 4.11. Potpuno iskorištenje procesora

U kontekstu raspoređivanja zadataka skup zadataka *potpuno iskorištava procesor* ako bilo koje povećanje računalnih vremena izvođenja bilo kojeg zadatka uzrokuje da sustav postaje nerasporediv zadanim postupkom.

Važno je shvatiti da potpuno iskorištenje procesora u ovom kontekstu ne mora označavati stopostotno iskorištenje procesora. Primjerice, sustav zadataka iz primjera 4.8. ima iskoristivost od 0,847 ali ipak u potpunosti iskorištava procesor prema definiciji 4.11. – u kritičnom slučaju se zadatak najmanjeg prioriteta jedva uspije dovršiti do iduće pojave – bilo kakvo povećanje vremena izračunavanja vodilo bi u prekoračenje zadanih vremenskih ograničenja.

Definicija 4.12. Najmanja gornja granica faktora procesorskog iskorištenja – $\mathrm{lub}(U)$

Najmanja gornja granica faktora procesorskog iskorištenja (engl. *least upper bound – lub*) je minimalna veličina faktora procesorskog iskorištenja svih mogućih skupova zadataka koji su rasporedivi i koji potpuno iskorištavaju procesor.

Slika 4.12. simbolički prikazuje sve moguće sustave od N zadataka i njihovu procesorsku iskoristivost. Do granice lub svi su sustavi rasporedivi. Od lub do 1 neki su rasporedivi, a neki nisu. Sustavi zadataka koji imaju procesorsku iskoristivost iznad 1 nisu rasporedivi (na jednoprocesorskim sustavima).

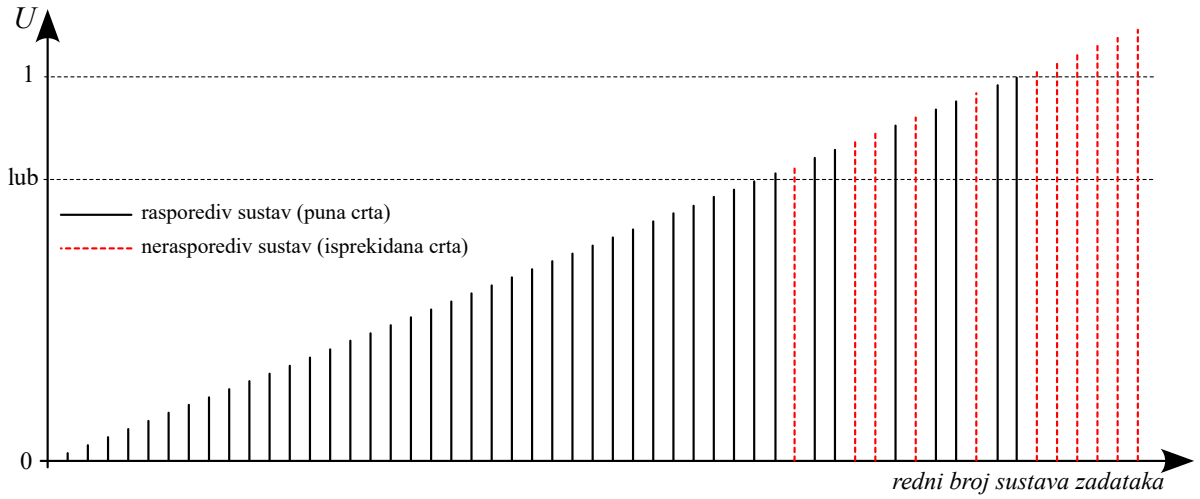

Slika 4.12. Primjeri sustava zadataka različitih faktora procesorskog iskorištenja

Sustavi zadataka s iskoristivošću manjom od lub ne koriste procesor potpuno, prema def. 4.11. (inače bi lub bio manji). To pak znači da su svi sustavi s manjom iskoristivošću od lub rasporedivi.

Rasporedivi sustavi zadataka s većom iskoristivošću od lub mogu ali i ne moraju potpuno koristiti procesor. Također, za njih ne možemo reći jesu li ili nisu rasporedivi – ne možemo sa sigurnošću reći da nisu rasporedivi, jer mogu biti, ali to treba provjeriti na druge načine.

Definicija 4.13. $\mathrm{lub}(U)$ **za sustav zadataka koji koristi mjeru ponavljanja**

Najniža gornja granica faktora iskorištenja procesora za sustav $\mathcal{S}$ sa N zadataka (prema definiciji 4.1.) koji se raspoređuju prema prioritetu koji su dodijeljeni zadacima mjerom ponavljanja (prema definiciji 4.5.) je:

$$\mathrm{lub}(U) = N\left(\sqrt[N]{2} - 1\right)$$

Dokaz definicije 4.13. prikazan je u [Liu, 1973].

Definicija 4.14. Dovoljan uvjet rasporedivosti kada se koristi mjera ponavljanja

Sustav $\mathcal{S}$ sa N zadataka (prema definiciji 4.1.) sigurno se može rasporediti postupkom mjere ponavljanja (prema definiciji 4.5.), ako za njegov faktor iskorištenja procesora $U_{\mathcal{S}}$ vrijedi:

$$U_{\mathcal{S}} \leq \mathrm{lub}(U) \tag{4.9.}$$

Definicija 4.14. definira rasporedivost sustava samo ako je $U_{\mathcal{S}}$ u granicama $[0, \mathrm{lub}(U)]$. Kada $U_{\mathcal{S}}$ pada u granice $\langle \mathrm{lub}(U), 1]$ rasporedivost treba provjeriti drugim kriterijima, primjerice grafičkim postupkom ili općim kriterijem rasporedivosti.

Što u sustavu ima više poslova teže ih je rasporediti, iako je možda njihovo ukupno opterećenje jednako. To prikazuje i definicija 4.13. te tablica 4.1. Ipak "umjereno velik" skup poslova bit će rasporediv ako operećenje koje on stvara ne prelazi otprilike 0,7 (70 %).

Tablica 4.1. $\mathrm{lub}(U)$ **za različiti broj zadataka**

N	1	2	3	4	5	10	100	1000	10^{10}	∞
$\mathrm{lub}(U)$	1	$0,83$	$0,78$	$0,76$	$0,74$	$0,72$	$0,696$	$0,6934$	$0,6931$	$\ln 2$

4.5.2. Jednoprocesorsko dinamičko raspoređivanje

Dinamički postupci raspoređivanja koriste obilježja zadataka koja se mijenjaju tijekom rada zadataka ili samim protokom vremena ili drugim događajima koji se zbivaju tijekom rada.

Primjerice, ako se neki zadatak u različitim intervalima javlja s različitom učestalošću, on bi u svakom od intervala trebao imati različitu vrijednost prioriteta, a da bi se mogao raspoređivati prema postupku mjere ponavljanja. Dinamička promjena prioriteta morala bi se ugraditi dodatnim postupcima te bi u konačnici globalni sustav raspoređivanja bio dinamički.

4.5.2.1. Raspoređivanje prema rokovima završetaka zadataka

Sa stanovišta SRSV-a, najznačajniji postupak raspoređivanja iz kategorije dinamičkih postupaka jest raspoređivanje prema rokovima završetaka zadataka – RZ (engl. *earliest deadline first – EDF, deadline driven scheduling – DDS*).

Definicija 4.15. Raspoređivanje prema rokovima

Raspoređivanje prema rokovima je postupak raspoređivanja koji u svakom trenutku za izvođenje odabire zadatak koji ima najbliži rok.

Da bi sustav zadataka $\mathcal{S}$ (prema definiciji 4.1.) bio rasporediv ovom metodom dovoljno je da vrijedi nužan uvjet rasporedivosti prema definiciji 4.3.

Ako dva ili više zadatka u nekom trenutku imaju isti rok, odabir jednog od njih je ili proizvoljan ili se definiraju dodatni (sekundarni) kriteriji raspoređivanja (npr. red prispijeća, prioriteti).

Raspoređivač se poziva svaki put kada se dogodi neka promjena u sustavu, tj. kada se pojavi neki zadatak u sustavu ili kada neki zadatak završi s radom.

Raspoređivanje prema rokovima ne postavlja dodatne uvjete na faktor iskorištenja procesora,

tj. ako sustav zadataka zadovoljava nužan uvjet ($U \leq 1$) sustav je rasporediv ovim postupkom (dokaz je u [Liu, 1973]).

Raspoređivanje prema rokovima je složenije od raspoređivanja mjerom ponavljanja jer zahtjeva dodatna saznanja o zadacima, tj. njihove rokove. Zato se ovakvo raspoređivanje rjeđe susreće kao mehanizam u stvarnim operacijskim sustavima.

Primjer 4.9.

U ovom primjeru prikazano je korištenje raspoređivanja prema rokovima nad sustavom zadataka iz primjera 4.5. Zadaci u sustavu su:

$$\begin{aligned} Z_1: &\quad T_1 = 10 \text{ ms}, \quad C_1 = 5 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 5 \text{ ms} \\ Z_3: &\quad T_3 = 20 \text{ ms}, \quad C_3 = 1 \text{ ms} \end{aligned}$$

Nužan uvjet rasporedivosti:

$$U = \frac{C_1}{T_1} + \frac{C_2}{T_2} + \frac{C_3}{T_3} = \frac{5}{10} + \frac{5}{15} + \frac{1}{20} = 0,883 \leq 1 \quad \checkmark$$

Raspoređivanje prema rokovima (grafički), uz sekundarni kriterij prema redu prispijeća prikazano je slikom 4.13.

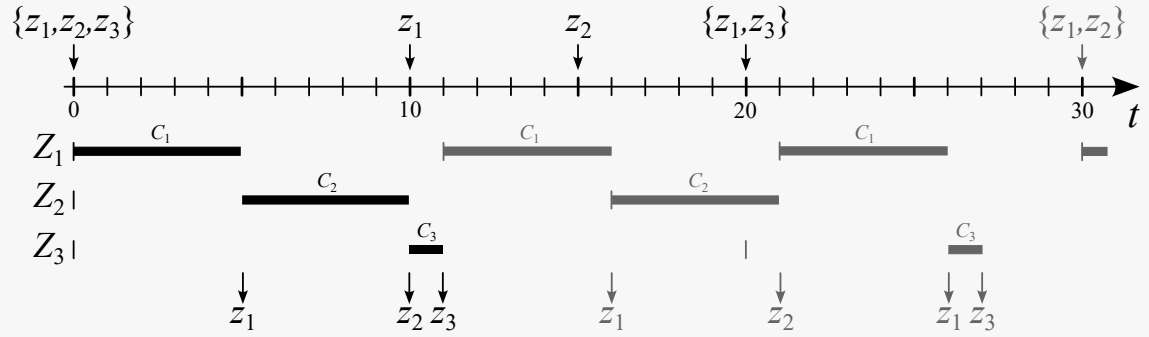

Slika 4.13.

Točke u kojima se pozivao raspoređivač uključuju sam početak, tj. trenutak pojave sva tri zadatka u t=0 ms, trenutak završetka prvog zadatka u t=5 ms, trenutak završetka drugog i istovremena pojava prvog zadatka (2. put) u t=10 ms, trenutak završetka trećeg zadataka i tako dalje. Primijetimo da u t=10 ms oba pripravna zadatka, i prvi i treći tada imaju isti rok $d = 20$ ms. Prema tome odabir koji će prije krenuti jest proizvoljan. U prikazanom rješenju sekundarni kriterij je red prispijeća te se odabrao treći zadatak jer on duže čeka u redu pripravnih zadataka.

Ako bi sekundarni kriterij bio prema mjeri ponavljanja (zadaci kraće periode imaju veći prioritet) tada bi raspoređivanje od 10. ms na dalje bilo ponešto drukčije, prema slici 4.14.

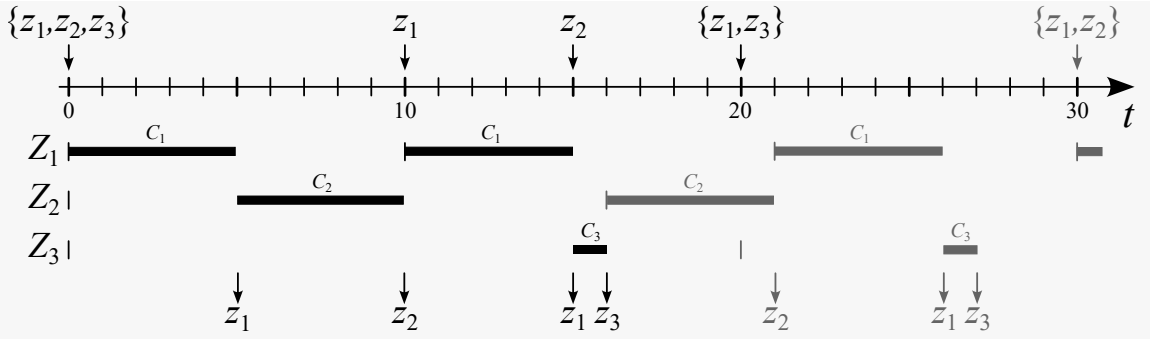

Slika 4.14.

4.6. Višeprocesorsko raspoređivanje

Korištenje višeprocesorskih računala u postupcima upravljanja ublažava problem rasporedivosti s obzirom na postojanje veće procesne moći. Svi prethodno navedeni postupci primjenjivi su i za raspoređivanje na višeprocesorskim računalima, uz male promjene s obzirom na to da će sada biti više aktivnih zadataka (dretvi). Primjerice, korištenjem postupka mjere ponavljanja na višeprocesorskom sustavu s M procesora, pri raspoređivanju uvijek će se odabrati M zadataka najvećeg prioriteta, a ne samo jedan kao kod jednoprocesorskog raspoređivanja.

Rasporedivost sustava zadataka na višeprocesorskom sustavu je u najgorem slučaju jednaka rasporedivosti u jednoprocesorskom, a u pravilu je povoljnija. Međutim, formule su složenije. Primjeri određivanja $\mathrm{lub}(U)$ za postupak mjere ponavljanja na višeprocesorskom računalu opisani su u [Baruah, 2003][Lopez, 2004][Jain, 1994] i sličnim radovima.

Sljedeća dva primjera prikazuju raspoređivanja istih skupova zadataka kao iz prethodnih primjera, ali sada na dvoprocesorskom računalu.

Primjer 4.10.

Prikažimo rad postupka mjere ponavljanja kada se primjenjuje na dvoprocesorskom računalu nad sustavom iz primjera 4.4.

$$\begin{aligned} Z_1: &\quad T_1 = 5 \text{ ms}, \quad C_1 = 2 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 5 \text{ ms} \\ Z_3: &\quad T_3 = 25 \text{ ms}, \quad C_3 = 5 \text{ ms} \end{aligned}$$

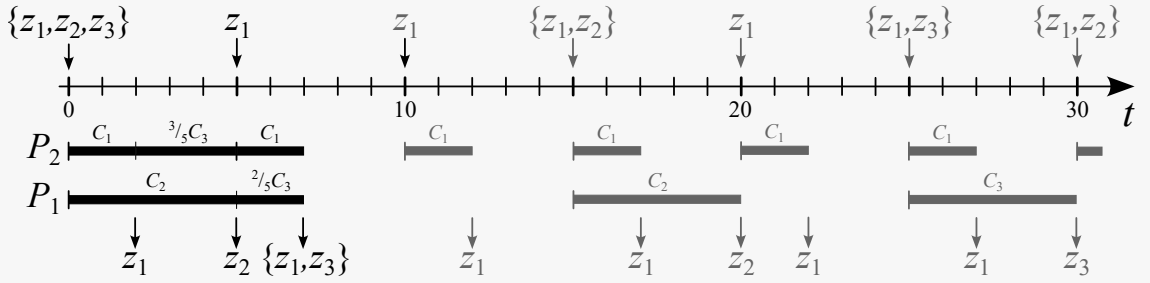

Slika 4.15.

Već se u 7. ms može zaključiti da je sustav rasporediv na dvoprocesorskom računalu (i stati

s daljnjom provjerom). Očito je problem olakšan, tj. takvi sustavi mogu zadovoljiti veći skup zadataka.

Primjer 4.11.

Prikažimo korištenje raspoređivanja prema rokovima za sustav zadataka iz primjera 4.5. na dvoprocesorskom sustavu:

$$Z_1: \quad T_1 = 10 \text{ ms}, \quad C_1 = 5 \text{ ms}$$
$$Z_2: \quad T_2 = 15 \text{ ms}, \quad C_2 = 5 \text{ ms}$$
$$Z_3: \quad T_3 = 20 \text{ ms}, \quad C_3 = 1 \text{ ms}$$

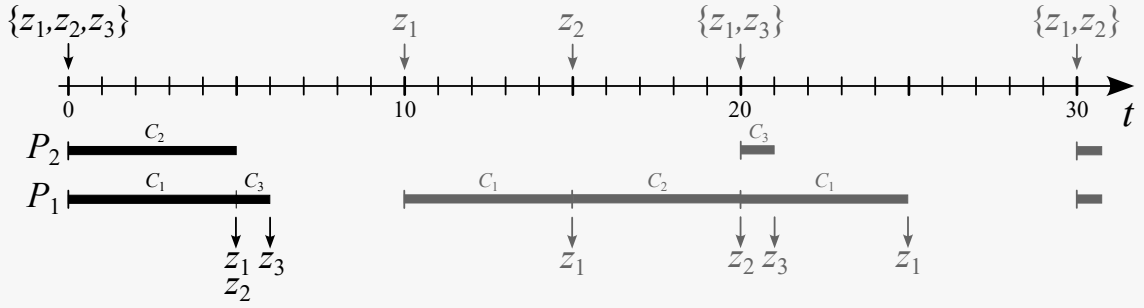

Slika 4.16.

I u ovom je primjeru provjera rasporedivosti mogla stati prije, u 6. ms s obzirom na to da je sustav razmatran u kritičnom slučaju.

Problem raspoređivanja na višeprocesorskim sustavima je ponešto olakšan naspram jednoprocesorskih. Nadalje, višeprocesorski sustav omogućava da se pri rješavanju jednog problema može koristiti paralelnost u izvođenju pojedinog posla. Paralelno izvođenje skupa nezavisnih zadataka je trivijalno. Međutim, ako među zadacima postoje ovisnosti tipa "Z_i se mora obaviti prije Z_j", tada je možda moguće optimirati redoslijed izvođenja zadataka na različitim procesorima tako da cijeli sustav zadataka završi prije. U nastavku se bavimo takvim problemima optimiranja.

4.6.1. Višeprocesorsko statičko raspoređivanje

U višeprocesorsko statičko raspoređivanje spada i već prikazani postupak mjere ponavljanja. S obzirom na njegovu sličnost s raspoređivanjem na jednoprocesorskim sustavima, ovdje se on više neće razmatrati. Postupci koji će se razmatrati u nastavku uključuju optimiranje nad uređenim skupom zavisnih zadataka, prema definiciji 4.16.

Definicija 4.16. Zavisnost zadataka

Zadaci Z_i i Z_j su zavisni zadaci ako postoji definirani redoslijed njihova izvođenja koji je potrebno poštivati. Redoslijed njihova izvođenja može biti:

$$Z_i < Z_j \quad \text{ili} \quad Z_j < Z_i$$

Operator $<$ označava relaciju "treba se dogoditi prije", odnosno označava da zadatak s lijeve strane operatora $<$ mora završiti prije nego li se zadatak s desne strane smije početi izvoditi.

Ako redoslijed njihova izvođenja nije definiran, odnosno ako se zadaci smiju izvoditi proizvoljnim redoslijedom, pa i paralelno, onda zadaci nisu međusobno zavisni.

Osim slučajeva opisanih u definiciji 4.16. postoji i treća mogućnost. Ako redoslijed izvođenja dvaju zadataka nije propisan, odnosno zadaci se smiju izvoditi proizvoljnim redoslijedom, ali ne smiju i paralelno, onda zadaci jesu na neki način međusobno zavisni. Takva zavisnost se ne iskazuje prema prethodnim relacijama već se takvi zadaci trebaju međusobno sinkronizirati mehanizmima međusobnog isključivanja. Takva zavisnost se ne razmatra u ovom poglavlju već u idućim.

Definicija 4.17. Skup zavisnih zadataka

Sustav zavisnih zadataka definira se skupom $\mathcal{S} = \{Z_1, Z_2, \ldots, Z_N\}$, s vremenima trajanja njihova izvođenja $\{C_1, C_2, \ldots, C_N\}$ te skupom zavisnosti:

$$\mathcal{R} = \{(i,j), \quad i,j \in \{1..N\} \quad | \quad i < j\}$$

gdje svaki par iz skupa $\mathcal{R}$ definira zavisnost između zadataka Z_i i Z_j prema:

$$Z_i < Z_j$$

uz značenje operatora $<$ prema definiciji 4.16.

Zbog uvjeta $i < j$ skup zadataka prema definiciji 4.17. ne može biti ciklički. U praksi se često koristi ciklički sustav zadataka kod kojeg postoji jedan početni zadatak (koji jedini može krenuti na početku) te jedan završni zadatak (koji može krenuti tek po završetku svih ostalih). Po završetku završnog zadatka može krenuti iduća iteracija sustava, tj. ponovno početni zadatak. Ovakav se ciklički sustav za jednu iteraciju može analizirati i bez ovisnosti među završnim i početnim zadatkom te tada i takav sustav zadovoljava definiciju 4.17.

Skup zavisnih zadataka se često prikazuje usmjerenim grafom. Primjer takvog grafa je već prikazan prije, uz ideju podjele posla na zadatke, na slici 4.2. Nekoliko drugih grafova je prikazano u primjerima koji slijede opis općeg raspoređivanja.

4.6.1.1. Opće raspoređivanje

Opće raspoređivanje (engl. *general scheduling*) [Nissanke, 1997] je teoretsko raspoređivanje koje razmatra procesore kao poslužitelje koje se može koristiti i samo djelomično, tj. u određenom postotku kroz neke vremenske intervale. Dio procesorske snage koju sustav može dodijeliti zadatku Z_i označava se s α_i, za koji mora vrijediti $0 \leq \alpha_i \leq 1$.

Primjerice, neki zadatak u takvom razmatranju može koristiti 25 % procesora P_1 kroz neki period. Ipak, rezultati i takvog teoretskog razmatranja, tj. raspoređivanja, se naknadno mogu prilagoditi u nešto praktično, npr. zadatak neće dobiti 25 % od P_1 kroz period od 10 sekundi nego će dobiti 100 % od P_1 u intervalu $[7,5; 10]$.

Definicija 4.18. Opće raspoređivanje

Opće raspoređivanje sustava zavisnih zadataka $\mathcal{S} = \{Z_1, Z_2, \ldots, Z_N\}$ na m procesora

raspodjeljuje zadatke po procesorima u svrhu njihova što skorijeg završetka tako da se raspoređivanje razmatra u intervalima Δt_k u kojima vrijedi:

1. podskup zadataka koji se izvode $\mathcal{S}' = \{Z_a, Z_b, \dots\}$ čine međusobno nezavisni zadaci
2. svaki zadatak Z_i iz $\mathcal{S}'$ koristi udio procesorske snage $\alpha_{i,k}$ za koji vrijedi:

$$0 \leq \alpha_{i,k} \leq 1$$

3. zadaci koji nisu u $\mathcal{S}'$ imaju: $\alpha_{j,k} = 0$
4. svi zadaci iz $\mathcal{S}'$ koriste dio raspoložive procesorske snage:

$$\sum_{i=1}^{N} \alpha_{i,k} \leq m.$$

Opće raspoređivanje nema podlogu u stvarnoj primjeni, ono je hipotetsko i predstavlja samo podlogu za ostvarenje raspoređivanja koje će optimalno iskoristiti dane procesore na načelima prekidljivog raspoređivanja.

U primjerima u nastavku je korišten pojednostavljeni algoritam ostvarenja općeg raspoređivanja koji uzima u obzir samo dio grafa. Stoga rezultati koji se na ovaj način dobivaju nisu uvijek optimalni, odnosno najčešće nisu optimalni kada (pri rješavanju) dođe do neuravnoteženosti u dijelu grafa.

Primjer 4.12.

Sustav zadataka zadan je necikličkim računalnim grafom na slici 4.17. Uz svaki zadatak Z_i zadano je i njemu potrebno procesorsko vrijeme C_i. Napraviti raspoređivanje sustava zadataka korištenjem postupka općeg raspoređivanja za dva procesora.

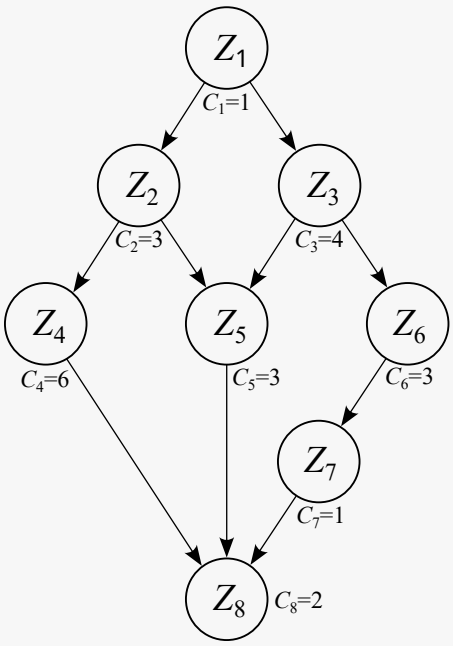

Slika 4.17.

Prvi interval koji se razmatra s općim raspoređivanjem započinje pojavom zadatka Z_1. S

obzirom na to da nije zadano vrijeme njegove pojave pretpostavlja se $t = 0$. Jedinice vremena nisu zadane te se neće niti koristiti (mogu biti sekunde, milisekunde, ...).

Interval-1: $t_1 = 0$

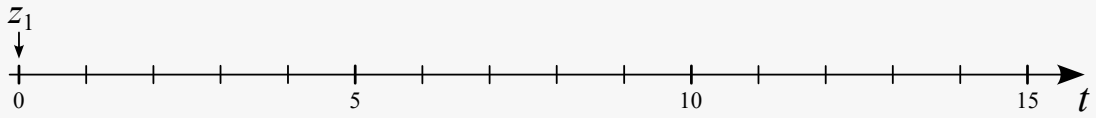

Pripravni zadatak: $Z_1(C_1 = 1)$
S obzirom na to da postoji samo jedan zadatak, a dva raspoloživa procesora:

$$\alpha_1 = 1 \Rightarrow T_{z1} = C_1/\alpha_1 = 1 \Rightarrow t_2 = t_1 + T_{z1} = 1$$

T_{zi} označava trajanje izvođenja zadatka i uz α_i.

Interval-2: $t_2 = 1$

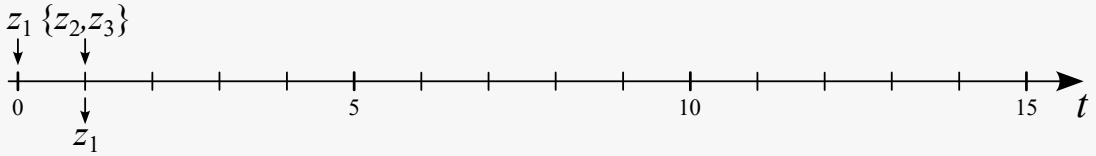

Pripravni zadaci: $Z_2(C_2 = 3), Z_3(C_3 = 4)$

$$\left.\begin{array}{l}\alpha_2 = 1 \Rightarrow T_{z2} = C_2/\alpha_2 = 3 \\ \alpha_3 = 1 \Rightarrow T_{z3} = C_3/\alpha_3 = 4\end{array}\right\} \Rightarrow t_3 = t_2 + \min\{T_{z2}, T_{z3}\} = 4$$

Interval-3: $t_3 = 4$

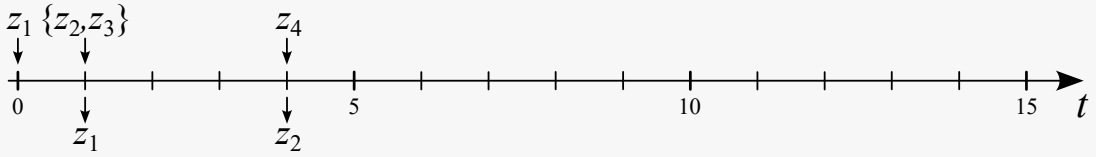

Pripravni zadaci: $Z_3(C_3^{(2)} = 1), Z_4(C_4 = 6)$

$$\left.\begin{array}{l}\alpha_3 = 1 \Rightarrow T_{z3} = C_3^{(2)}/\alpha_3 = 1 \\ \alpha_4 = 1 \Rightarrow T_{z4} = C_4/\alpha_4 = 6\end{array}\right\} \Rightarrow t_4 = t_3 + \min\{T_{z3}, T_{z4}\} = 5$$

Interval-4: $t_4 = 5$

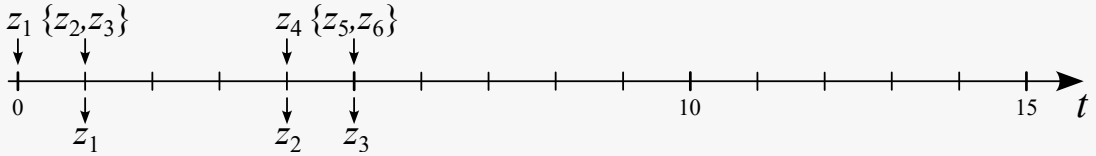

Pripravni zadaci: $Z_4(C_4^{(2)} = 5), Z_5(C_5 = 3), Z_6(C_6 = 3)$

Tri zadatka na dva procesora: kako odrediti raspored, a da bi sustav u najkraćem vremenu sve završio?

Kada bi to bili zadnji zadaci u sustavu, ili kada bi svima slijedio isti zadatak, onda bi se omjeri udjela procesorskog vremena tako podesili da svi završe u istom trenutku (ako je to moguće), koristeći oba procesora. Primjerice Z_4 bi dobio $\alpha_4 = (C_4^{(2)}/(C_4^{(2)} + C_5 + C_6)) \cdot 2 = 10/11$ (množi se s 2 zbog dva procesora), a ostala dva prema sličnim formulama po $6/11$ udjela u procesorskom vremenu. Međutim, to nisu takvi zadaci.

Uvidom u graf i trenutno stanje, može se primjetiti da zadatak Z_7 slijedi neposredno iza Z_6, a da njemu kao i zadacima Z_4 i Z_5 slijedi Z_8. Prethodno razmatranje moglo bi se primijeniti kada bismo objedinili zadatke Z_6 i Z_7 u jedan zadatak Z_σ, barem za potrebe izrade rasporeda.

Pripravni zadaci: $Z_4(C_4^{(2)} = 5), Z_5(C_5 = 3), Z_\sigma(C_\sigma = C_6 + C_7 = 4)$

$$\Delta t = \frac{C_4^{(2)} + C_5 + C_\sigma}{2} = \frac{5+3+4}{2} = \frac{12}{2} = 6 \text{ (potrebno procesorskog vremena)}$$
$$\alpha_4 = C_4^{(2)}/\Delta t = 5/6$$
$$\alpha_5 = C_5/\Delta t = 3/6$$
$$\alpha_\sigma = C_\sigma/\Delta t = 4/6$$

S obzirom na to da su svi α_i manji od 1 raspored će biti optimalan – oba procesora će biti iskorištena cijelo vrijeme ($\Delta t = 6$). Kada to ne bi bilo tako, kada bi primjerice α_4 po prethodnom proračunu bio veći od jedan (kada bi sustav od tri zadatka bio van ravnoteže – kada bi jedan zadatak imao više posla od zbroja druga dva), tada bi pri optimiranju trebalo postaviti $\alpha_4 = 1$ i s time nastaviti optimizaciju.

Skup zadatka $\{Z_4, Z_5, Z_\sigma\}$ završit će za $\Delta t = 6$.

Međutim, s obzirom na to da se Z_σ sastoji od Z_6 i Z_7, prvi od njih Z_6 bit će gotov i prije:

$$T_{z6} = C_6/\alpha_\sigma = 3/(4/6) = 9/2 = 4,5 \;\Rightarrow\; t_5 = 9,5$$

Nakon Z_6 u sustav dolazi Z_7 te zajedno s Z_4 i Z_5 završava u $t_6 = 11$.

Interval-5: $t_5 = 11$

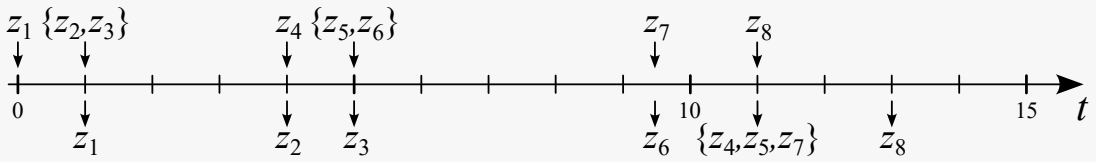

Pripravni zadaci: $Z_8(C_8 = 3)$

$$\alpha_8 = 1 \;\Rightarrow\; T_{z8} = C_8/\alpha_8 = 2 \;\Rightarrow\; t_7 = t_6 + T_{z8} = 13$$

Interval-6: $t_6 = 13$

Završetkom zadnjeg zadatka završava sustav zadataka (prema općem raspoređivanju).

Korištenjem rezultata općeg raspoređivanja može se napraviti stvaran raspored zadataka po procesorima (uz $\alpha_i = 1$ po segmentima) pretpostavljajući da se zadaci mogu prekidati (prekidljivo raspoređivanje), kao što to prikazuje slika 4.18.

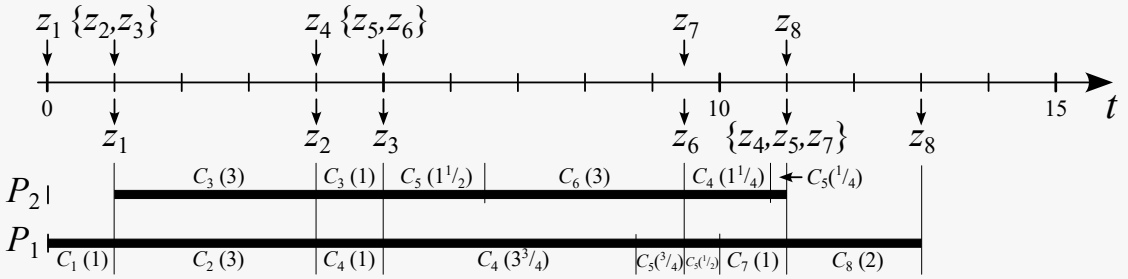

Slika 4.18.

Do $t = 5$, raspored je jednostavan. U intervalu $[5; 9, 5]$ potrebno je smjestiti Z_4, Z_5 i Z_6 s prethodno izračunatim vremenima za taj interval. Kako će se to napraviti nije predefinirano, može i drukčije nego što je prikazano na prethodnoj slici. Ono na što treba pripaziti je da se osigura da u svakom trenutku na različitim procesorima budu različiti zadaci. Analogno za interval $[9, 5; 11]$.

Naravno, kada bismo slagali ručno, bez korištenja rezultata općeg raspoređivanja, možda bi došli do jednostavnijeg rasporeda, npr. kao na slici 4.19. Međutim, to je moguće samo u jednostavnijim slučajevima, ne i općenito.

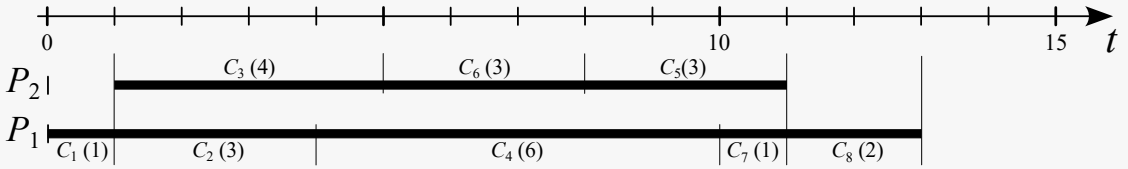

Slika 4.19.

"Ručno slaganje" kao na slici 4.19. nije valjano rješenje u zadacima u kojima se traži korištenje rezultata općeg raspoređivanja.

Primjer 4.13.

Sustav zadataka zadan je necikličkim računalnim grafom na slici 4.20. Napraviti raspoređivanje sustava zadataka korištenjem postupka općeg raspoređivanja za dva procesora.

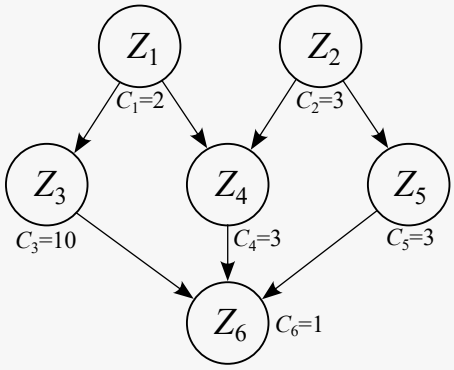

Slika 4.20.

Interval-1: $t_1 = 0$

Pripravni zadaci: $Z_1(C_1 = 2), Z_2(C_2 = 3)$

$$\left.\begin{array}{l} \alpha_1 = 1 \;\Rightarrow\; T_{z1} = C_1/\alpha_1 = 2 \\ \alpha_2 = 1 \;\Rightarrow\; T_{z2} = C_2/\alpha_2 = 3 \end{array}\right\} \;\Rightarrow\; t_2 = t_1 + \min\{T_{z1}, T_{z2}\} = 2$$

Interval-2: $t_2 = 2$

Pripravni zadaci: $Z_2(C_2^{(2)} = 1), Z_3(C_3 = 10)$

$$\left.\begin{array}{l} \alpha_2 = 1 \;\Rightarrow\; T_{z2} = C_2^{(2)}/\alpha_2 = 1 \\ \alpha_3 = 1 \;\Rightarrow\; T_{z3} = C_3/\alpha_3 = 10 \end{array}\right\} \;\Rightarrow\; t_3 = t_2 + \min\{T_{z2}, T_{z3}\} = 3$$

Interval-3: $t_3 = 3$

Pripravni zadaci: $Z_3(C_3^{(2)} = 9), Z_4(C_4 = 3), Z_5(C_5 = 3)$

$$\Delta t = \frac{C_3^{(2)} + C_4 + C_5}{2} = \frac{9+3+3}{2} = \frac{15}{2}$$
$$\alpha_3 = C_3^{(2)}/\Delta t = 18/15$$
$$\alpha_4 = C_4/\Delta t = 6/15$$
$$\alpha_5 = C_5/\Delta t = 6/15$$

Problem: $\alpha_3 > 1$!

Stavljamo: $\alpha_3 = 1$ a za ostala dva ostaje drugi procesor koji se dijeli na:

$$\Delta t^{(2)} = \frac{C_4 + C_5}{1} = \frac{3+3}{1} = 6$$
$$\alpha_4 = C_4/\Delta t = 3/6 = 1/2$$
$$\alpha_5 = C_5/\Delta t = 3/6 = 1/2$$

$$\left.\begin{array}{l}\alpha_3 = 1 \;\Rightarrow\; T_{z3} = C_3^{(2)}/\alpha_3 = 9 \\ \alpha_4 = 1/2 \;\Rightarrow\; T_{z4} = C_4/\alpha_4 = 6 \\ \alpha_5 = 1/2 \;\Rightarrow\; T_{z5} = C_5/\alpha_5 = 6\end{array}\right\} \Rightarrow\; t_4 = t_3 + \min\{T_{z3}, T_{z4}, T_{z5}\} = 3 + 6 = 9$$

Interval-4: $t_4 = 9$

Pripravni zadatak: $Z_3(C_3^{(3)} = 3)$

$\alpha_3 = 1 \;\Rightarrow\; T_{z3} = C_3^{(3)}/\alpha_3 = 3 \;\Rightarrow\; t_5 = t_4 + T_{z3} = 12$

Interval-5: $t_5 = 12$

Pripravni zadatak: $Z_6(C_6 = 1)$

$\alpha_6 = 1 \;\Rightarrow\; T_{z6} = C_6/\alpha_6 = 1 \;\Rightarrow\; t_6 = t_5 + T_{z6} = 13$

Interval-6: $t_6 = 13$

Sustav je prema općem raspoređivanju gotov u $t = 13$.

Zbog neuravnoteženosti u ovom primjeru jedan od procesora miruje i usred izvođenja sustava, a ne samo na početku i/ili kraju kao što je to uobičajeno.

Primjer 4.14.

Sustav zadataka zadan je necikličkim računalnim grafom na slici 4.21. Napraviti raspoređivanje sustava zadataka korištenjem postupka općeg raspoređivanja za dva procesora.

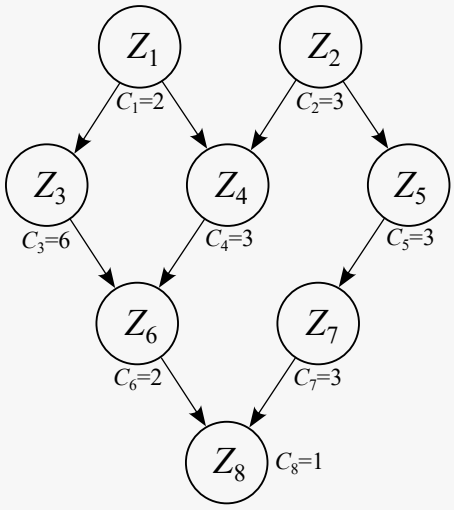

Slika 4.21.

Interval-1: $t_1 = 0$

Pripravni zadaci: $Z_1(C_1 = 2), Z_2(C_2 = 3)$

$$\left.\begin{array}{l} \alpha_1 = 1 \;\Rightarrow\; T_{z1} = C_1/\alpha_1 = 2 \\ \alpha_2 = 1 \;\Rightarrow\; T_{z2} = C_2/\alpha_2 = 3 \end{array}\right\} \Rightarrow\; t_2 = t_1 + \min\{T_{z1}, T_{z2}\} = 2$$

Interval-2: $t_2 = 2$

Pripravni zadaci: $Z_2(C_2^{(2)} = 1), Z_3(C_3 = 6)$

$$\left.\begin{array}{l} \alpha_2 = 1 \;\Rightarrow\; T_{z2} = C_2^{(2)}/\alpha_2 = 1 \\ \alpha_3 = 1 \;\Rightarrow\; T_{z3} = C_3/\alpha_3 = 6 \end{array}\right\} \Rightarrow\; t_3 = t_2 + \min\{T_{z2}, T_{z3}\} = 3$$

Interval-3: $t_3 = 3$

Pripravni zadaci: $Z_3(C_3^{(3)} = 5), Z_4(C_4 = 3), Z_5(C_5 = 3)$

Supstitucija:

$$Z_{\sigma_1} = \{Z_3, Z_4, Z_6\} \qquad C_{\sigma_1} = C_3^{(3)} + C_4 + C_6 = 5 + 3 + 2 = 10$$
$$Z_{\sigma_2} = \{Z_5, Z_7\} \qquad C_{\sigma_2} = C_5 + C_7 = 3 + 3 = 6$$

$$\Delta t = \frac{C_{\sigma_1} + C_{\sigma_2}}{2} = 8$$
$$\alpha_{\sigma_1} = C_{\sigma_1}/\Delta t = 10/8 = 5/4$$
$$\alpha_{\sigma_2} = C_{\sigma_2}/\Delta t = 6/8 = 3/4$$

Iako je $\alpha_{\sigma_1} > 1$ to će se u početku dijelom moći iskoristiti s obzirom na to da se Z_{σ_1} sastoji od dva zadatka koji mogu paralelno.

$$\Delta t^{(1)} = \frac{C_3^{(3)} + C_4}{\alpha_{\sigma_1}} = \frac{5+3}{5/4} = 32/5$$
$$\alpha_3 = C_3^{(3)}/\Delta t^{(1)} = 5/(32/5) = 25/32$$
$$\alpha_4 = C_4/\Delta t^{(1)} = 3/(32/5) = 15/32$$
$$T_{z3} = C_3^{(3)}/\alpha_3 = 5/(25/32) = 32/5$$
$$T_{z4} = C_4/\alpha_4 = 3/(15/32) = 32/5$$
$$t_{z3} = t_3 + 32/5 = 3 + 6,4 = 9,4$$

Od $t = 9,4$ na dalje bi zadatak Z_6 sam imao na raspolaganju $\alpha_{\sigma_1} = 5/4$ što ne može iskoristiti. Ako drugi podsustav zadataka nije gotov, ovdje se može ponovno napraviti preraspodijela.

$$\alpha_5 = \alpha_{\sigma_2} = 3/4$$
$$T_{z5} = C_5/\alpha_5 = 3/(3/4) = 4$$
$$t_{z5} = t_3 + T_{z5} = 3 + 4 = 7$$

U intervalu $[7; 9,4]$ zadatak Z_7 koristit će i dalje isti $\alpha_7 = \alpha_{\sigma_2}$.

$$\alpha_7 = \alpha_{\sigma_2} = 3/4$$
$$\Delta t^{(2)} = 9,4 - 7 = 2,4$$
$$C_7^{(1)} = \Delta t^{(2)} \cdot \alpha_7 = 2,4 \cdot (3/4) = 1,8$$
$$C_7^{(2)} = C_7 - C_7^{(1)} = 3 - 1,8 = 1,2$$

Interval-4: $t_4 = 9,4$

Pripravni zadaci: $Z_6(C_6 = 2), Z_7(C_7^{(2)} = 1,2)$

$$\left.\begin{array}{l} \alpha_6 = 1 \Rightarrow T_{z6} = C_6/\alpha_6 = 2 \\ \alpha_7 = 1 \Rightarrow T_{z7} = C_7^{(2)}/\alpha_7 = 1,2 \end{array}\right\} \Rightarrow t_5 = t_4 + \min\{T_{z6}, T_{z7}\} = 10,6$$

Interval-5: $t_5 = 10,6$

Pripravni zadatak: $Z_6(C_6^{(2)} = 2 - 1,2 = 0,8)$

$\alpha_6 = 1 \Rightarrow T_{z6} = C_6^{(2)}/\alpha_6 = 0,8 \Rightarrow t_6 = t_5 + T_{z6} = 11,4$

Interval-6: $t_6 = 11,4$

Pripravni zadatak: $Z_8(C_8 = 1)$

$\alpha_8 = 1 \Rightarrow T_{z8} = C_8/\alpha_8 = 1 \Rightarrow t_7 = t_6 + T_{z8} = 12,4$

Interval-7: $t_7 = 12,4$

Sustav zadataka završava u $t_7 = 12,4$.

U ovom primjeru zbog pojave neuravnoteženosti u zadacima u dijelu postupka, dobiveno rješenje nije potpuno optimalno (kada bismo ručno optimirali mogli bi posložiti zadatke tako da završe do 12. jedinice vremena). Međutim, ovo nije svojstvo općeg raspoređivanja, već pojednostavljenog algoritma za njegovo ostvarenje koje je korišteno u ovim primjerima.

4.6.1.2. Postupak sa stablenom strukturom

Postupak raspoređivanja sa stablenom strukturom jednostavan je grafički postupak primjenjiv na sustave zadataka kod kojih su ovisnosti prikazane grafom koji ima stablenu strukturu, s time da su početni zadaci u listovima stabla, a završni zadatak predstavlja korijen. Svaki zadatak u takvom sustavu ima najviše jednog neposrednog slijednika, osim završnog zadatka koji nema slijednika.

Izrada rasporeda kreće od kraja, od trenutka kada zadnji zadatak (korijen) treba završiti. Od tog trenutka kreće se unatrag, do trenutka kad on treba započeti, a njegovi prethodnici završiti. Isti se postupak dalje primjenjuje za svaki od njegovih prethodnika, pa njihovih prethodnika, sve do listova.

Grafički postupak ne uzima u obzir broj raspoloživih procesora, odnosno pretpostavlja da ih ima dovoljno da se svi paralelni zadaci mogu paralelno izvoditi. Logička visina stabla u tom slučaju predstavlja duljinu najduljeg puta (zbroj trajanja zadataka na putu od lista do korjena).

Stvarno trajanje izvođenja sustava zadataka raspoređenog ovim postupkom može biti dulje. Postupak, slično kao i opće raspoređivanje, pretpostavlja da će svi paralelni zadaci dijeliti raspoloživu procesorsku snagu u istim omjerima (uz ograničenje $\alpha_i \leq 1$). Za zadani broj procesora se može odrediti "stvarna visina" grafa – trajanje pojedinih segmenata, kao i izvođenje cijelog sustava.

Postupak neće uvijek stvoriti optimalno rješenje kao opće raspoređivanje, ali je zato mnogo jednostavniji.

Primjer 4.15.

Sustav zadataka zadan je stablenom strukturom prema slici 4.22.

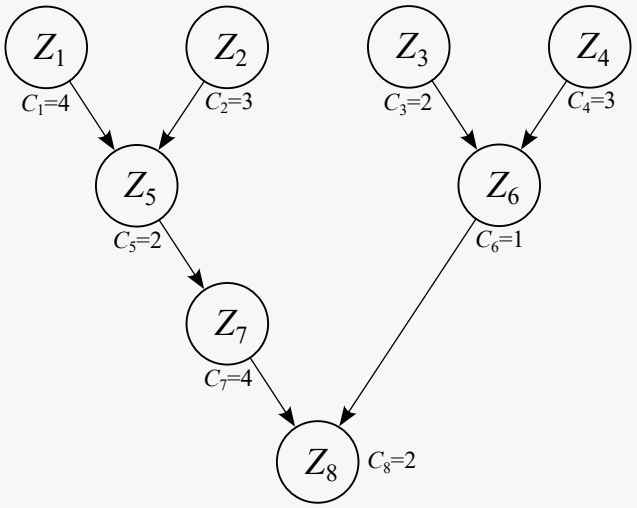

Slika 4.22.

Rješenje raspoređivanja korištenjem postupka sa stablenom strukturom je prikazano slikom 4.23. U rješenju se kreće od trenutka kada su svi zadaci obavljeni do kraja (od dna slike) te se vraća prema gore (u stablu). Prvi zadatak kojeg se ucrtava je zadatak Z_8. On traje 2 jedinice vremena. Prije nego li Z_8 krene moraju biti gotovi i Z_6 i Z_7 (te njih crtamo povrh Z_8). Z_6 traje jednu jedinicu vremena, a Z_7 četiri. Sva se ta trajanja koriste pri crtanju grafa. S lijeve strane su označene logičke visine stabla u jedinicama trajanja. Istim postupkom nacrtaju se i ostale grane, sve do listova. Rezultat postupka daje trenutke kada treba pokrenuti pojedini zadatak.

Razmotrimo raspoređivanje na dvoprocesorskom računalu. Prema slici 4.23., samo se u segmentu od $h = 3$ do $h = 5$ pojavljuju tri zadatka (po ovakvom raspoređivanju) te je trajanje izvođenja tog segmenta dulje od visine segmenta: $\Delta t = \Delta h \cdot 3/2 = 2 \cdot 3/2 = 3$. Ukupno trajanje izvođenja sustava zadataka raspoređenih zadanim postupkom dobiva se zbrajanjem trajanja svih segmenata. Za ovaj primjer ukupno trajanje iznosi 13 jedinica vremena.

Analizom grafa, mogli bi doći do nekih opažanja. Primjerice, iako su početno četiri zadatka neovisna, samo se jedan, Z_1, odabire za izvođenje. Kada bismo sve pustili, to ne bi dalo bolje rješenje. Međutim, zadatak Z_2 bi mogao krenuti istovremeno, ali će tada završiti prije prvog zadatka.

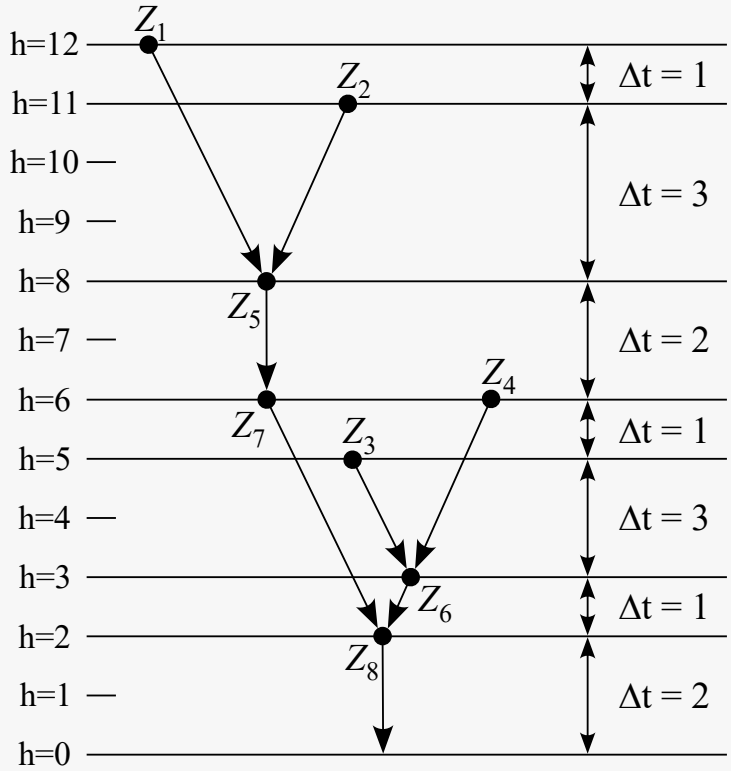

Slika 4.23. Raspoređivanje stablenom strukturom na dvoprocesorskom računalu

Ipak, kada bismo naknadno "ručno" popravljali ovaj raspored, mogli bi Z_3 pokrenuti zajedno s Z_5 te bi tada u svakom segmentu imali najviše dva zadatka i sustav bi mogao biti gotov jednu jedinicu prije. Međutim, "ručno" popravljanje je moguće samo za jednostavne sustave. S druge strane, prikazani postupak raspoređivanja sa stablenom strukturom može se ostvariti jednostavnim programom i primijeniti na složene sustave zadataka (uz pretpostavku stablaste strukture).

4.6.2. Višeprocesorsko dinamičko raspoređivanje

Postupci dinamičkog raspoređivanja ostvaruju svoju učinkovitost oslanjanjem na relativno jednostavne kriterije koji su tipično vezani na neka obilježja zadataka, kao što su rok završetka ili hitnost izvođenja zadatka. Cilj im je izbjeći računalno skupo optimiranje rasporeda, tako da sustav može brzo odgovoriti na promjene u okolini.

Dinamičko raspoređivanje prema rokovima na višeprocesorskim sustavima je identično kao i na jednoprocesorskim sustavima i već je ilustrirano primjerom 4.11. te se neće dodatno analizirati u osnovnom obliku. Međutim, poznavanje roka te preostalog vremena potrebnog za izvođenje zadatka $c(t)$ može se iskoristiti za drugi kriterij – kriterij hitnosti započinjanja zadatka, odnosno koliko se dugo zadatak može još odgoditi prije početka izvođenja, a da se ipak stigne izvesti do kraja prije svog roka. Kriterij se naziva po mogućoj odgodi zadatka – kriterij labavosti.

4.6.2.1. Labavost

Labavost (engl. *laxity, slack time*) označava vrijeme koje zadatak može provesti bez da se izvodi, a da se ipak kasnije stigne obaviti prije svog roka.

Definicija 4.19. Labavost

Neka je zadatak Z u trenutku t zadan s $Z(t) = \{C(t), d\}$, gdje $C(t)$ predstavlja preostalo potrebno procesorsko vrijeme za završetak zadatka te d rok završetka. Labavost zadatka $\ell(t)$ definira se prema:

$$\ell(t) = d - t - C(t) \tag{4.10.}$$

Veličina $đ(t) = d - t$ predstavlja vrijeme do roka ("relativan d"). Preko $đ(t)$ labavost se definira s:

$$\ell(t) = đ(t) - C(t) \tag{4.11.}$$

Labavost se može uzeti kao mjera hitnosti pokretanja zadatka. Što je labavost veća, hitnost je manja, pa se pri nekom raspoređivanju mogu uzimati najprije zadaci najveće hitnosti.

Raspoređivanje prema najmanjoj labavosti (NL, *least laxity first – LLF*) koristi informaciju o rokovima zadataka, ali i o potrebnim vremenima izvođenja zadataka. S obzirom na tu dodatnu informaciju postupak može dati bolji raspored od samog postupka prema rokovima.

Prema trenutnoj vrijednosti labavosti mogu se donijeti neki zaključci o stanju zadatka:

- $\ell(t) > 0$ – postoji dovoljno vremena za izvođenje zadatka, nije neophodno odmah započeti s njegovim izvođenjem, već se početak još može odgoditi za najviše $\ell(t)$
- $\ell(t) = 0$ – zadatak treba odmah započeti s izvođenjem i ne prekidati izvođenje do njegova završetka, inače se neće stići obaviti do d
- $\ell(t) < 0$ – zadatak se više sigurno ne stigne obaviti do d (koji je možda već i prošao).

Raspoređivanje primjenom labavosti može se prikazati grafički u ℓ/c prostoru. Zadatak se u grafu ucrtava u trenutku kada se zadatak javlja u sustavu. Labavost se računa prema definiciji 4.19. te se zadatak ucrtava u graf s vrijednostima $(\ell(t), c(t))$.

Primjer 4.16.

Slika 4.24. prikazuje primjer ℓ/c grafa s tri zadatka u trenutku t.

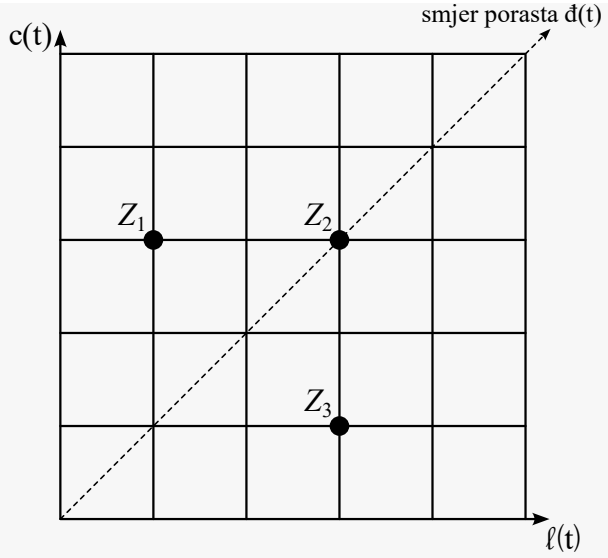

Slika 4.24. ℓ/c **graf u trenutku t**

Labavost, preostalo vrijeme računanja te vrijeme do roka u trenutku t može se očitati i izračunati iz grafa sa slike 4.24. prema:

$$\begin{aligned}
Z_1: &\quad C_1(t) = 3, \quad \ell_1(t) = 1, \quad đ_1(t) = \ell_1(t) + C_1(t) = 4 \\
Z_2: &\quad C_2(t) = 3, \quad \ell_2(t) = 3, \quad đ_2(t) = \ell_2(t) + C_2(t) = 6 \\
Z_3: &\quad C_3(t) = 1, \quad \ell_3(t) = 3, \quad đ_3(t) = \ell_3(t) + C_3(t) = 4
\end{aligned}$$

Raspoređivač prema labavosti bi prvo odabrao zadatak Z_1 s obzirom na to da je njegova labavost najmanja. Nakon njega bi odabir između Z_2 i Z_3 bio proizvoljan s obzirom na to da je njihova labavost jednaka, ili bi se koristio sekundarni kriterij (primjerice, prema rokovima).

Raspoređivač prema rokovima bi u početku odabrao Z_1 ili Z_3 s obzirom na to da imaju istu vrijednost $đ$ (vrijeme do roka).

4.6.2.2. Zalihost računalne snage

Uzimajući u obzir labavost pojedinih zadataka iz skupa zadataka $\mathcal{S}$, moguće je izračunati zalihost računalne snage za budući interval vremena, tj. koliko se procesorske snage može odvojiti za neke druge poslove, a da se razmatrani skup zadataka ipak stigne obaviti do kraja uz poštivanje svih vremenskih ograničenja.

Definicija 4.20. kaže da se pri računanju zalihosti za budući period duljine x, od raspoložive računalne snage $m \cdot x$ treba oduzeti vrijeme potrebno za dovršetak svih zadataka koji moraju biti gotovi do $t + x$, ali također i dio vremena za zadatke čija je labavost manja od x (oni mogu propustiti najviše ℓ svog vremena u idućih x jedinica vremena).

Definicija 4.20. Zalihost računalne snage – $F(m, \mathcal{S}, t, x)$

U trenutku t zalihost računalne snage u sustavu s m procesora za budući period $[t, t + x]$

iznosi:

$$F(m, \mathcal{S}, t, x) = m \cdot x - \sum_{Z \in R_1} C_Z(t) - \sum_{Z \in R_2} (x - \ell_Z(t))$$

gdje $R_1 \subseteq \mathcal{S}$ predstavlja skup zadataka koji moraju biti gotovi do trenutka $t + x$, tj.

$$đ_Z(t) = C_Z(t) + \ell_Z(t) \leq x \quad \forall Z \in R_1$$

dok $R_2 \subseteq \mathcal{S}$ predstavlja skup zadataka koji trebaju djelomično obaviti svoj posao u intervalu $[t, t + x]$, a da bi stigli obaviti završiti prije svog d, tj.

$$đ_Z(t) > x \quad \wedge \quad \ell_Z(t) < x, \quad \forall Z \in R_2$$

Primjer 4.17. Zalihost računalne snage

Slika 4.25. prikazuje primjer ℓ/c grafa s kojeg se može izračunati zalihost računalne snage za interval $[t; t + 5]$.

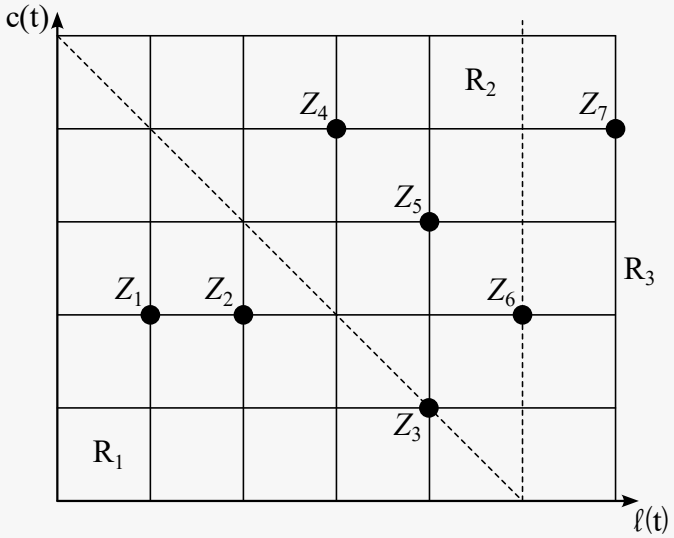

Slika 4.25. Podjela ℓ/c grafa u područaja pri određivanju zalihosti

Zadaci $\{z_1, z_2, z_3\}$ spadaju u skup R_1, zadaci $\{z_4, z_5, z_6\}$ u skup R_2 te $\{z_7\}$ spada u skup R_3. Zadaci na granicama područja mogu se pripojiti jednom ili drugom području – jednako utječu na zalihost.

Na slici 4.26. prikazani su svi zadaci tako da im je na početku stavljena labavost a iza toga preostalo vrijeme obrade. Iz te slike jasnije se vidi koje zadatke ili njihove dijelove treba obaviti do trenutka $t + 5$.

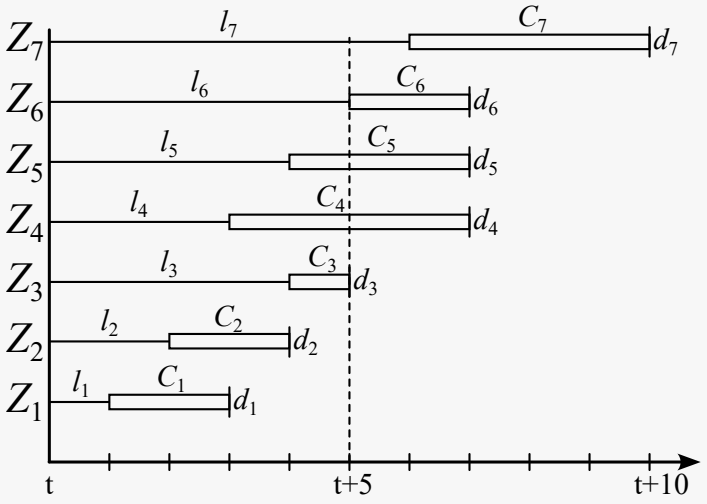

Slika 4.26. Svojstva pojedinih zadataka u trenutku t

$$\begin{aligned} F(m,\mathcal{S},t,5) &= m\cdot 5-(C_1(t)+C_2(t)+C_3(t))-((5-\ell_4)+(5-\ell_5)+(5-\ell_6)) \\ &= m\cdot 5-(2+2+1)-((5-3)+(5-4)+(5-5)) \\ &= m\cdot 5-5-3=m\cdot 5-8 \end{aligned}$$

Primjerice, za dvoprocesorski sustav zalihost iznosi: $F(2,\mathcal{S},t,5)=2\cdot 5-8=2$.

4.6.2.3. Raspoređivanje prema labavosti i rokovima

Za sustave za rad u stvarnom vremenu raspoređivanje prema rokovima se pokazuje, bar teoretski, kao jedan od najboljih postupaka. Raspoređivanje korištenjem najmanje labavosti implicitno koristi rokove te također spada u istu grupu teoretski najboljih raspoređivača.

Za razliku od raspoređivača prema rokovima koji se treba koristiti u trenucima promjena u sustavu (promjena u pripravnim zadacima), raspoređivač koji koristi labavost bi se trebao pozivati i samim protokom vremena jer se labavost vremenom smanjuje. Ipak, u sljedećim zadacima pretpostavlja se da se raspoređivač pokreće periodički sa zadanim intervalom između dva poziva. Naime, ostvarenja takvog raspoređivača u okviru nekog operacijskog sustava bi također trebala uzeti neki period pozivanja raspoređivača.

Rad oba postupka na istom problemu raspoređivanja korištenjem grafičkog postupka preko ℓ/c grafa prikazan je primjerom 4.18.

Primjer 4.18.

Sustav zadataka u trenutku $t=0$ zadan je ℓ/c grafom na slici 4.27. Dodatno je poznato da će se u trenutku $t=1$ pojaviti još jedan zadatak s potrebnim vremenom računanja od 2 jedinice koji mora biti gotov do $t=4$. Prikazati rad raspoređivača prema najmanjoj labavosti kao primarnom kriteriju i prema rokovima kao sekundarnom, i obratno. Na raspolaganju je dvoprocesorsko računalo, a raspoređivač se poziva nakon svake jedinice vremena (za raspoređivanje prema NL).

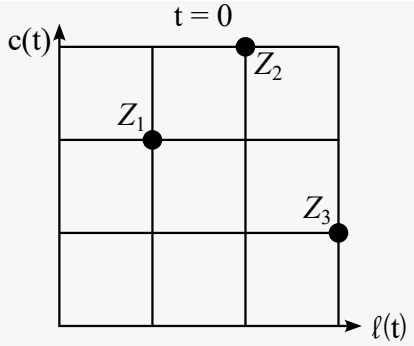

Slika 4.27. Početno stanje sustava zadataka

Raspoređivanje prema najmanjoj labavosti za izvođenje najprije odabire zadatke koji su na ℓ/c grafu najbliže osi $c(t)$. Kada više zadataka ima istu labavost, tada se odabir mora napraviti po dodatnom kriteriju. U ovom primjeru dodatni kriterij jest prema rokovima. U grafičkom postupku simulacije rada sustava na ℓ/c grafu, pomak zadataka u prethodnom intervalu prikazan je strelicama. Zadaci odabrani za izvođenje na grafu će se spustiti po vertikalnoj osi (smanjuje se c), dok će se svi ostali pomakuti lijevo (smanjuje se ℓ).

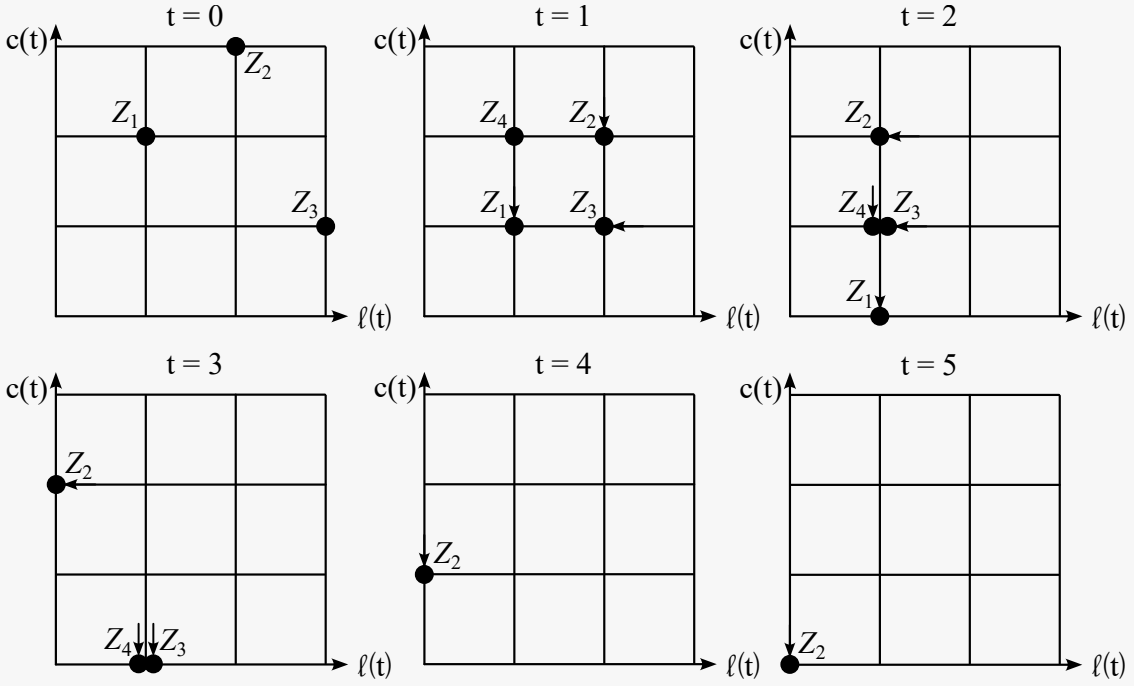

Slika 4.28. Raspoređivanje prema najmanjoj labavosti

U trenutku $t = 1$ u sustavu, pa time i na grafu pojavljuje se novi zadatak Z_4. S obzirom na to da on treba završiti za 3 jedinice vremena od kojih su mu dvije potrebne na procesoru, labavost mu je 1.

Raspoređivanje prema rokovima je slično, jedino je odabir zadataka drukčiji – prvo se biraju zadaci s najbližim rokom koji su na grafu najbliži pravcu $c = -\ell$. Slika 4.24. prikazuje smjer porasta rokova.

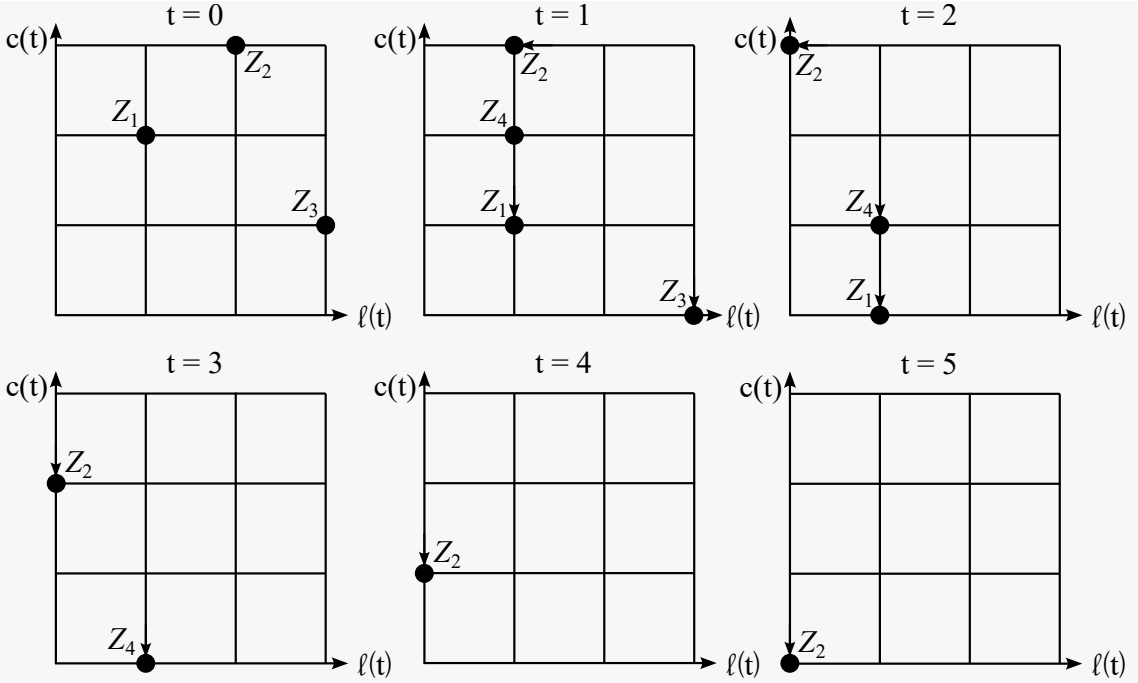

Slika 4.29. Raspoređivanje prema rokovima

Usporedbom oba postupka raspoređivanja na zadanom primjeru ne uočava se razlika u kvaliteti raspoređivanja.

4.7. Postupci raspoređivanja i njihova optimalnost

Optimalnost postupaka raspoređivanja može se promatrati s nekoliko raznih gledišta. Neki od njih su:

1. zadovoljavanje vremenskih ograničenja zadataka – izvedivost raspoređivanja
2. jednostavnost postupka:
   - radi mogućnosti ostvarenja u stvarnim sustavima
   - radi smanjenja procesne snage utrošene na odlučivanje o raspoređivanju i kućanske poslove raspoređivača
   - radi malog broja potrebnih obilježja zadataka koji su dostupni unaprijed ili za vrijeme izvođenja
3. optimiranje završetka skupine zavisnih zadataka.

4.7.1. Optimalnost prema izvedivosti raspoređivanja

Optimalnost postupaka za raspoređivanje zadataka odnosi se na prednosti jednih u odnosu na druge, unutar iste klase postupaka. Usporedba postupaka različitih klasa često nema smisla s obzirom na to da one mogu tražiti poznavanje različitih informacija o zadacima. Postupci raspoređivanja razmatrani u ovom poglavlju mogu se podijeliti u nekoliko klasa:

1. postupci za jednoprocesorske sustave sa statičkom dodjelom prioriteta
2. dinamički postupci za jednoprocesorske sustave

3. dinamički postupci za višeprocesorske sustave.

Definicija 4.21. Optimalan postupak raspoređivanja

Za postupak raspoređivanja se može reći da je optimalan ako se njime može rasporediti bilo koji skup zadataka koji se može rasporediti i nekim drugim postupkom iz iste klase raspoređivača.

Nužan uvjet za rasporedivost sustava zadataka na jednoprocesorskom sustavu jest da ukupni faktor iskorištenja koji stvaraju ti zadaci bude manji od jedan (definicija 4.3.). S obzirom na to da je isti uvjet dostatan i za raspoređivanje prema rokovima proizlazi da je taj postupak optimalan za jednoprocesorske sustave. Isto vrijedi i za postupak prema najmanjoj labavosti (koji nije zasebno razmatran za jednoprocesorske sustave).

Postupak mjere ponavljanja optimalan je postupak raspoređivanja među postupcima sa statičkom pridjelom prioriteta zadacima na jednoprocesorskim sustavima (dokaz u [Liu, 1973]).

Optimalnost glede izvodljivosti raspoređivanja na višeprocesorskim sustavima je mnogo složenija. O samoj izvodljivosti raspoređivanja (najboljim mogućim postupkom) moglo bi se zaključiti prema zalihosti procesne snage.

Definicija 4.22. Izvodljivost raspoređivanja

Nužan i dovoljan uvjet za izvodljivost raspoređivanja sustava zadataka (nekim optimalnim postupkom) jest:

$$F(m, \mathcal{S}, t, x) \geq 0, \quad \forall x > 0$$

gdje $F(m, \mathcal{S}, t, x)$ predstavlja zalihost računalne snage u intervalu $[t, t + x]$ koji se izračunava prema definiciji 4.20.

Definicija 4.22. poopćuje nužan uvjet rasporedivosti iz definicije 4.3. (koji vrijedi samo za jednoprocesorske sustave) na višeprocesorske sustave. Postavlja se pitanje postoji li postupak raspoređivanja koji će za svaki sustav zadataka koji zadovoljava definiciju 4.22. dati zadovoljiv raspored?

Za razliku od jednoprocesorskih sustava, postupak prema rokovima nije optimalan za višeprocesorske sustave. Slika 4.30. prikazuje primjer sustava u ℓ/c prostoru koji postupak prema rokovima (RZ) ne uspije rasporediti na dvoprocesorskom sustavu, dok postupak prema najmanjoj labavosti (NL) to uspijeva.

Je li onda možda NL optimalan? Da bi dobili negativan odgovor dovoljno je pronaći neki sustav koji jest rasporediv nekom metodom, ali ga NL ne uspijeva rasporediti. Jedan takav sustav prikazuje primjer 4.19. Dakle, ni NL nije optimalan.

Primjer 4.19. Sustav koji NL ne može rasporediti

Neka je zadan sustav periodičkih zadataka koji treba izvoditi na dvoprocesorskom raču-

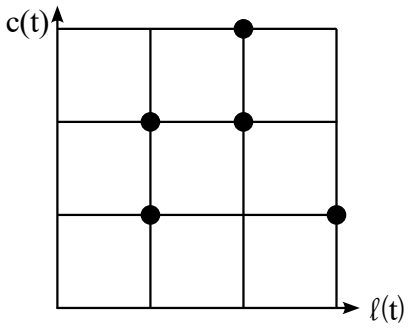

Slika 4.30. Primjer sustava gdje RZ ne uspijeva, a NL uspijeva rasporediti sustav zadataka na dvoprocesorskom računalu

nalu:

$$
\begin{aligned}
Z_1: &\quad T_1 = 5 \text{ ms}, \quad C_1 = 4 \text{ ms} \\
Z_2: &\quad T_2 = 5 \text{ ms}, \quad C_2 = 4 \text{ ms} \\
Z_3: &\quad T_3 = 10 \text{ ms}, \quad C_3 = 4 \text{ ms}
\end{aligned}
$$

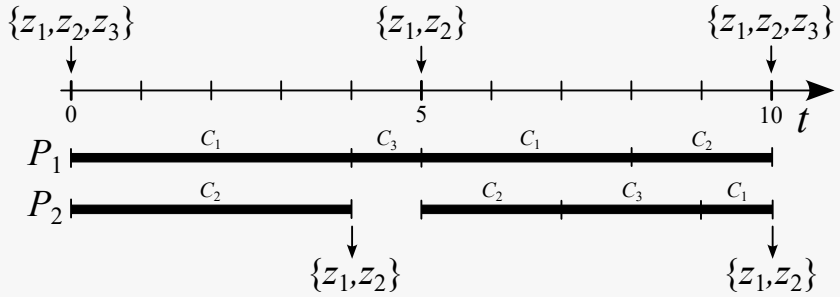

Slika 4.31. NL raspoređivanje uz indeks zadatka kao drugi kriterij

NL (s bilo kojim sekundarnim kriterijem) neće uspjeti rasporediti sustav jer Z_3 neće dobiti dovoljno procesorskog vremena u prvih 10 ms s obzirom na to da tamo ima najmanju labavost.

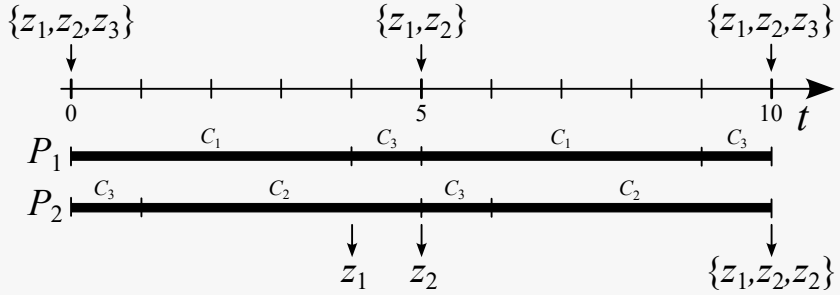

Slika 4.32. Raspored (ručni) koji zadovoljava sva ograničenja

4.8. Problemi određivanja rasporeda u stvarnim sustavima

U stvarnim sustavima mnogi parametri zadataka nisu unaprijed dovoljno precizno poznati ili su čak promjenjivi tijekom rada. U takvim okolnostima mnoge teorije/definicije iz ovog poglavlja nisu (u potpunosti) valjane.

Nadalje, što sa zadacima koji se ne smiju prekidati tijekom izvođenja? Statička dodjela prioriteta se pokazuje problematičnom i često nije dovoljno koristiti mjeru ponavljanja. Možda jedan od jednostavnijih i dovoljno dobrih za mnoge primjene je raspoređivanje prema rokovima.

Problem raspoređivanja je još uvijek aktualan problem, i nakon više od pola stoljeća istraživanja. Opće rješenje, "najbolje za sve" još nije pronađeno, ali su zato predložena mnoga druga rješenja koja "dovoljno dobro" (najbolje do sada) rješavaju probleme u pojedinim okruženjima.

U stvarnim sustavima optimalan raspored je gotovo nemoguće postići. Zato se traži najbolji mogući raspored koji praktični algoritmi mogu izračunati u ograničenom (konačnom) vremenu. Ti su algoritmi uglavnom zasnovani na raznim heuristikama ili kombinatoričkom pretraživanju prostora (npr. genetski algoritmi).

U praksi se često (uz veću zalihost – manju procesorsku iskoristivost) kao najjednostavnije rješenje koristi prioritetno raspoređivanje, s time da se prioriteti zadacima dodjeljuju iskustvom arhitekta sustava, koji uzima u obzir mnoga obilježja zadataka, od mjere ponavljanja, bitnosti za sustav u kojem sudjeluju i slično. Za sustave koje takvo raspoređivanje ne zadovoljava, mora se najprije (prije pokretanja, *offline*) napraviti raspored koji zadovoljava sve uvjete za sve zadatke. Ako su zadaci periodički, onda se postupak optimiranja rasporeda radi na hiper-periodi (višekratniku perioda svih zadataka) – intervalu u kojem se sve ponavlja na jednak način. Takav raspored najčešće uključuje i ubacivanje praznog hoda, pogotovo ako se zadaci ne smiju prekidati. Raspored se može prikazati i tablicom koja se onda koristi pri odabiru idućeg zadatka za raspoređivanje.

4.8.1. Statičko raspoređivanje za jednostavne zadatke

U jednostavnijim sustavima koji koriste mikrokontrolere zadaci upravljanja su uglavnom jednostavni i međusobno nezavisni. Zadaci mogu biti periodički ili sporadički. Za periodičke zadatke treba napraviti raspoređivanje dok se sporadični javljaju i obrađuju mehanizmom prekida (ali ih ipak treba uzeti u obzir prilikom raspoređivanja periodičkih).

Pretpostavke za jednostavne zadatke i sustav takvih zadataka:

- Svako pokretanje zadatka je nezavisno od prethodnog pokretanja – osim podataka u strukturama podataka ne pamti se kontekst zadatka od jednog pokretanja do drugog – za svako pokretanje dovoljno je pozvati funkciju s kodom za taj zadatak.
- Izvođenje svakog zadatka treba trajati kratko – najdulje dopušteno vrijeme izvođenje treba biti poznato unaprijed. Ako bi se ponekad to vrijeme pokušalo premašiti, to treba zaustaviti, primjerice nadzornim alarmom.
- Pokretanje (skupa) zadataka obavlja se na alarm – periodički prekid sata.
- Zadaci ne uključuju blokirajuće pozive – ne blokiraju se tijekom izvođenja.
- Zadaci su međusobno nezavisni, ne koriste sinkronizacijske i komunikacijske mehanizme.
- Zadaci se mogu prekidati prekidima, ali ne drugim zadacima.
- Ako su trajanja izvođenja pojedinih zadataka dosta promjenjiva, da bi sustav bio (uvijek) rasporediv potrebno je rezervirati dovoljno procesorskog vremena, odnosno iskoristivost sustava ne smije biti velika.

Statički raspored radi se za hiper-periodu – interval u kojemu se sve ponavlja. Hiper-perioda jednaka je najmanjem zajedničkom višekratniku perioda svih zadataka (engl. *The least common multiple – lcm*).

Jedan od načina izrade rasporeda izvođenja zadataka je da se hiper-perioda podijeli na kraće

odsječke te da se za svaki od njih izradi lista zadataka koje treba pokrenuti u tom odsječku. Navedeno je ilustrirano primjerom 4.20.

Primjer 4.20. Zadaci po odsječcima

Zadan je sustav koji se sastoji od jednostavnih periodičkih zadataka Z_1–Z_4 s periodama $T_1 = 1$ ms, $T_2 = 2$ ms, $T_3 = 4$ ms te $T_4 = 8$ ms. Očekivana trajanja izvođenja zadataka su do 300 μs po zadatku. Osim navedenih zadataka sustav obrađuje i sporadične zadatke koje obrađuje mehanizmom prekida. Uz pretpostavku da sporadični zadaci neće uzeti više od 100 μs unutar svake milisekunde, napraviti jedan statički raspored zadataka i pokazati funkciju za obradu alarma koji se javlja svake 1 ms.

Jedno moguće rješenje:

Hiper-perioda je $T_H = \mathrm{lcm}(1, 2, 4, 8) = 8$ ms. Može ju se podijeliti u odsječke različitih veličina. U ovom rješenju odabrana je duljina od 1 ms i za svaki takav odsječak napravljen zaseban raspored.

Prvi zadatak Z_1 će se pojaviti u svakom odsječku jednom.

Zadatak Z_2 će se pojaviti u svakom drugom, počevši od prvog.

Zadatak Z_3 bi također mogli staviti u prvi odsječak, ali onda ne bilo ništa slobodna prostora za eventualne prekide (osim jednog sporadičnog zadatka) ili eventualno prekoračenje izvođenja od 300 μs nekog od zadataka. Stoga je u predloženom rješenju za Z_3 kao prvi odsječak odabran drugi (i svaki četvrti idući, tj. šesti u hiper-periodi).

Zadatak Z_4 je sličnom logikom kao i za Z_3 postavljen u četvrti odsječak.

1			2			3			4			5			6			7			8	
Z_1	Z_2	–	Z_1	Z_3	–	Z_1	Z_2	–	Z_1	Z_4	–	Z_1	Z_2	–	Z_1	Z_3	–	Z_1	Z_2	–	Z_1	–

Slika 4.33. Zadaci po odsječcima hiper-periode

Ostvarenje upravljanja u pseudokodu pretpostavlja da su zadane funkcije za svaki zadatak. Neka su one označene sa `z1`, `z2`, `z3` i `z4`. Tada rješenje može izgledati kao u nastavku.

```
//zadaci po odsječcima
Z[] = {{z1,z2}, {z1,z3}, {z1,z2}, {z1,z4}, {z1,z2}, {z1,z3}, {z1,z2}, {z1}}

//idući odsječak
t = 0 //u ovom rješenju indeksi idu od 0 do 7

alarm_svake_1ms
   za i = 0 do duljina_niza(Z[t])-1
      Z[t][i]() //pozovi funkciju zadatka
   t = (t + 1) mod 8

glavni_program
   prazna beskonačna petlja
```

U rješenju se na svaki prekid alarma pokrenu zadaci raspoređeni u taj odsječak (određen varijablom `t`).

Problem može nastati kad neki zadatak ne završi u predviđenom intervalu. Problem je moguće riješiti na razne načine, korištenjem nadzorna alarma, prilagodbom funkcije za obradu alarma ili drukčije. Rješenje jako ovisi o zahtjevima sustava i potrebnim akcijama

u slučaju prekoračenja.

Drugi način, prikladniji kada u sustavu postoji puno zadataka koji se mogu rasporediti u nekoliko kategorija, jest korištenjem kraćih odsječaka u kojem se izvodi samo po jedan zadatak (ili se ništa ne izvodi), a odabir se određuje prikladno izgrađenim tablicama. Idući primjer 4.20. prikazuje jednu takvu mogućnost.

Primjer 4.21. Tablični raspored

U sustavu se nalaze zadaci različita tipa (A, B, C) tako da se svaki zadatak treba obaviti jednom unutar svoje periode. Zadaci tipa A su a_1, a_2 i a_3 s periodom $T_A = 1$ ms. Zadaci tipa B su b_1, b_2 $\ldots b_{15}$ s periodom $T_B = 5$ ms. Zadaci tipa C su c_1, c_2 $\ldots c_{17}$ s periodom $T_C = 20$ ms. Očekivano trajanje zadataka je ispod 100 μs. Zadatke treba pokretati na alarm.

Jedno moguće rješenje:

Period s kojim se alarm javlja postavljen je na svakih 100 μs što daje 10 mogućnosti za pokretanje zadataka unutar svake milisekunde.

Zadaci tipa A se svi moraju pojaviti unutar svake milisekunde.

Zadaci tipa B, njih 15, se svi moraju pojaviti jednom unutar svakih 5 ms. Kada bi ih jednoliko rasporedili u tom intervalu, tada unutar jedne milisekunde treba izvesti po 3 zadatka tipa B.

Na sličan način možemo zaključiti da bi po jedan zadatak tipa C trebalo izvesti svake milisekunde s time da u tri milisekunde (od 20) taj tip zadatka ne bi bio prisutan. Da se pojednostavi takav problem, najjednostavnije je dodati tri prazna zadatka tipa C tako da se i te tri milisekunde popune takvim tipom zadataka.

Ukupno bi unutar jedne miliskenude trebalo obaviti: 3 zadatka tipa A, 3 zadatka tipa B te jedan tipa C što ukupno čini 7 zadataka. Uz ubacivanje praznih intervala, mogući raspored izvođenja zadataka unutar svake milisekunde može biti kao na slici 4.34.

1	2	3	4	5	6	7	8	9	10
A	B	–	A	B	–	A	B	C	–

Slika 4.34. Raspored poziva tipova zadataka unutar jedne milisekunde

U različitim prekidima alarma označenim istim tipom zadatka treba pozvati različite zadatke. Primjerice, prva oznaka B će biti poziv `b1`, druga `b2`, treća `b3`, četvrta (kada krene iduća milisekunda) `b4`, pa `b5` i tako dalje sve do `b15` te onda opet `b1` i dalje. Slično je za zadatke tipa A i C. Primjer rješenja u obliku pseudokoda, uključujući strukture podataka i funkciju alarma naveden je u nastavku.

```
//kazaljke na funkcije, zasebno po tipovima zadataka
zadA[] = {a1, a2, a3}
zadB[] = {b1, b2, b3, b4, b5, b6, b7, b8, b9, b10, b11, b12, b13, b14, b15}
zadC[] = {c1, c2, c3, c4, c5, c6, c7, c8, c9, c10, c11, c12, c13, c14, c15,
          c16, c17, ništa, ništa, ništa} // "ništa" je prazna funkcija

zad[] = {zadA, zadB, zadC} //zad[x][y] = kazaljka na y-tu funkciju tipa x

//redoslijed tipova zadataka unutar milisekunde: 0=A, 1=B, 2=C, -1=ništa
```

```
slijed[] = {0, 1, -1, 0, 1, -1, 0, 1, 2, -1}

//koji po redu prekid unutar milisekunde (odabir elementa iz slijed[])
t = 0

//idući zadatak prema tipovima (A, B, C)
ind[] = {0, 0, 0} //odabir zadatka iz zad[slijed[t]][]
MAXTIP [] = {3, 15, 20}

alarm_svakih_100us
   tip = slijed[t]                //koji je tip zadatka na redu
   ako je tip != -1 tada
      zad[tip][ind[tip]]()        //pozovi funkciju koja obavlja zadatak
      ind[tip] = (ind[tip] + 1) mod MAXTIP[tip]
   t = (t + 1) mod 10

glavni_program
   prazna beskonačna petlja
```

Svakih 100 μs javlja se prekid alarma i u njemu pokreće jedan zadatak, osim ako taj odsječak nije prazan. O kojemu se zadatku radi ovisi o odsječku koji određuje tip zadatka te o zadatku tog tipa koji je sada na redu (`zad[tip][ind[tip]]`).

Pitanja za vježbu 4

1. Navesti razloge korištenja višedretvenosti općenito te u SRSV-ima.
2. Koji su osnovni problemi pri korištenju višedretvenosti?
3. Svaki pojedinačni zadatak ima neka vremenska svojstva. Koja? Kako ona utječu na korisnost zadatka te koje zahtjeve postavljaju prema operacijskom sustavu?
4. Opisati opća svojstva statičkih i dinamičkih postupaka raspoređivanja.
5. Što je to "procesorska iskoristivost" te što se preko nje može zaključiti o rasporedivosti sustava zadataka?
6. Opisati raspoređivanje mjerom ponavljanja (engl. *rate monotonic scheduling*).
7. Opisati korištenje "općeg kriterija rasporedivosti" za provjeru rasporedivosti sustava zadataka kada se koristi raspoređivanje mjerom ponavljanja.
8. Što je to "implicitni trenutak krajnjeg završetka" nekog zadatka?
9. U kontekstu raspoređivanja periodičkih zadataka objasniti razliku između krajnjeg trenutka završetka i implicitna krajnjeg trenutka završetka.
10. Kada se za neki sustav zadataka kaže da "u potpunosti iskorištava procesor" (u kontekstu raspoređivanja tih zadataka nekim postupkom)?
11. Što je to "najmanja gornja granica procesorskog iskorištenja" $\mathrm{lub}(U)$? Koji se zaključci mogu donijeti za sustave za koje vrijedi $U_{\mathcal{S}} \leq \mathrm{lub}(U)$, odnosno, za one koje ista nejednakost ne vrijedi?
12. Opisati raspoređivanje korištenjem postupka prema krajnjim trenucima završetka za-

dataka (engl. *earliest deadline first*). Navesti dobra i loša svojstva tog postupka.

13. Koje kriterije optimiranja koristi "opće raspoređivanje"?
14. Što je to labavost (u kontekstu zadatka i njegovog raspoređivanja)? Opisati raspoređivanje prema najmanjoj labavosti (engl. *least laxity first*)?
15. Što je to zalihost računalne snage (u kontekstu raspoređivanja)?
16. Koji je nužan i dovoljan uvjet za rasporedivost sustava zadataka na višeprocesorskom sustavu?
17. Za koji postupak raspoređivanja kažemo da je optimalan (u svojoj klasi)?
18. Korištenjem raspoređivanja prema mjeri ponavljanja provjeriti rasporedivost sustava zadataka na jednoprocesorskom sustavu korištenjem:
    a) procesorske iskoristivosti (nužni uvjet, lub)
    b) simulacijom (grafičkim postupkom)
    c) odrediti implicitne trenutke krajnjeg završetka za sve zadatke.

$$\begin{aligned} Z_1: &\quad T_1 = 10 \text{ ms}, \quad C_1 = 3 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 3 \text{ ms} \\ Z_3: &\quad T_3 = 20 \text{ ms}, \quad C_3 = 4 \text{ ms} \\ Z_4: &\quad T_4 = 30 \text{ ms}, \quad C_4 = 6 \text{ ms} \end{aligned}$$

    d) Je li navedeni sustav rasporediv korištenjem raspoređivanja prema krajnjim trenucima završetaka? Pokazati rad tog raspoređivača nad navedenim sustavom zadataka.
19. Korištenjem raspoređivanja prema krajnjim trenucima završetaka simulacijom raspoređivanja provjeriti rasporedivost sustava zadataka na dvoprocesorskom sustavu.

$$\begin{aligned} Z_1: &\quad T_1 = 10 \text{ ms}, \quad C_1 = 6 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 9 \text{ ms} \\ Z_3: &\quad T_3 = 20 \text{ ms}, \quad C_3 = 10 \text{ ms} \\ Z_4: &\quad T_4 = 30 \text{ ms}, \quad C_4 = 3 \text{ ms} \end{aligned}$$

20. Bez korištenja simulacije (ostalim postupcima: nužni uvjet, lub, ...) ispitati rasporedivost sustava zadataka na jednoprocesorskom sustavu ako se koristi:
    a) raspoređivanje mjerom ponavljanja
    b) raspoređivanje prema krajnjim trenucima završetaka.

$$\begin{aligned} Z_1: &\quad T_1 = 10 \text{ ms}, \quad C_1 = 2 \text{ ms} \\ Z_2: &\quad T_2 = 15 \text{ ms}, \quad C_2 = 3 \text{ ms} \\ Z_3: &\quad T_3 = 20 \text{ ms}, \quad C_3 = 5 \text{ ms} \\ Z_4: &\quad T_4 = 30 \text{ ms}, \quad C_4 = 3 \text{ ms} \end{aligned}$$

21. Pokazati rad raspoređivanja prema najmanjoj labavosti (LLF) za sustav iz prethodnog zadatka, uz dvostruko veća vremena računanja (redom 4, 6, 10, 6 ms), ako se on izvodi na dvoprocesorskom sustavu (pokazati rad u intervalu 0.–10. ms). Interval poziva raspoređivača (ponovni izračun labavosti) obavlja se svake 1 ms. Sekundarni kriterij kod raspoređivanja je mjera ponavljanja.

22. Zadaci Z_1 – Z_4 javljaju se u trenucima 1. ms, 2. ms, 3. ms te 4. ms (respektivno, Z_1 u 1.). Obrada svakog zadatka traje po 3 ms. Svi zadaci (i pojedinačno) moraju biti gotovi do 7. ms. Pokazati rad raspoređivača po najmanjoj labavosti (LLF) nad tim sustavom zadataka ako se koristi dvoprocesorski sustav. Naznačiti posebne trenutke u tom izvođenju (dolasci, odlasci, ...).

23. Korištenjem raspoređivanja prema najmanjoj labavosti te redu prispijeća kao sekundarnom kriteriju, grafički prikazati raspoređivanje sustava zadataka na dvoprocesorskom sustavu u intervalu [0,30].

$$
\begin{aligned}
Z_1 &: \quad T_1 = 10 \text{ ms}, \quad C_1 = 5 \text{ ms} \\
Z_2 &: \quad T_2 = 15 \text{ ms}, \quad C_2 = 7 \text{ ms} \\
Z_3 &: \quad T_3 = 20 \text{ ms}, \quad C_3 = 10 \text{ ms} \\
Z_4 &: \quad T_4 = 30 \text{ ms}, \quad C_4 = 15 \text{ ms}
\end{aligned}
$$

24. U trenutku t sustav je prikazan grafom prema slici 4.35.

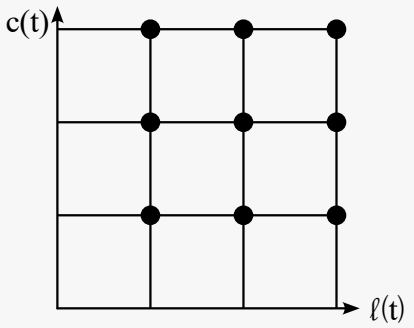

Slika 4.35. Primjer sustava zadataka u ℓ/c grafu

a) Koliko minimalno procesora sustav treba imati da bi se bilo kojim postupkom sustav mogao rasporediti? Prikazati provjeru korištenjem zalihosti računalne snage (definicija 4.22.).

b) Prikazati raspoređivanje sustava na četiri procesora korištenjem najmanje labavosti kao primarnim kriterijem te prema krajnjim trenucima završetka kao sekundarnim.

5. Raspoređivanje dretvi

U prethodnim odjeljcima je problem raspoređivanja teoretski razmatran te je prikazano nekoliko postupaka raspoređivanja.

1. Raspoređivanje prema mjeri ponavljanja radi tako da dretvama statički pridijeli prioritete te se pri radu koristi prioritetni raspoređivač.
2. Raspoređivanje prema rokovima te raspoređivanje prema najmanjoj labavosti rade tako da raspoređivač dinamički odlučuje o odabiru dretve s obzirom na to kada ona mora završiti svoj posao.
3. Opće raspoređivanje i raspoređivanje sa stablenom strukturom se primjenjuje na višeprocesorskim sustavima za optimiranje raspored skupa zavisnih zadataka.

Neki od navedenih postupaka spadaju u klasu statičkih raspoređivača koji odluke o značajkama raspoređivanja (njihove vrijednosti) donose prije pokretanja sustava, dok drugi postupci spadaju u klasu dinamičkih postupaka – značajke koje se koriste za raspoređivanje mijenjaju se tijekom rada zadataka kao i samim protokom vremena.

U praksi se nastoje preuzeti dobra svojstva pojedinih postupaka raspoređivanja, ali tako da sam postupak bude primjenjiv. S obzirom na to da je vrlo mali broj obilježja zadataka unaprijed poznat, koriste se jednostavniji postupci. Međutim, to ovisi o sustavu koji se razmatra. Negdje su i oni složeniji potrebni.

Raspoređivanje značajno ovisi o zahtjevima sustava. Sustavi za rad u stvarnom vremenu samo su jedna skupina sustava u kojoj se koriste računala. U druge skupine možemo ubrojati ugrađene sustave, osobna računala, radne stanice, poslužiteljska računala, prijenosna i mobilna računala (telefoni, tableti i slično). Svojstva zadataka u drugim sustavima nisu jednaka te identični način raspoređivanja dretvi ne mora biti najbolji. Primjerice, multimedijalni program ima svojstva slična zadacima sustava za rad u stvarnom vremenu: svako kašnjenje može izazvati osjetnu degradaciju kvalitete slike ili zvuka. Slično je i s korisničkim sučeljem: znatnija kašnjenja u reakciji na korisničke naredbe korisniku će umanjiti kvalitetu sustava. Ipak, u oba navedena primjera loše raspoređivanje neće izazvati znatne štete (osim smanjenja kvalitete sustava prema ocjeni korisnika). Operacije koje dulje traju, kao što su matematički proračuni, kompresija podataka i prijenos datoteka, mogu se još malo odgoditi bez umanjenja kvalitete sustava, s obzirom na to da korisnik već očekuje njihovo produljeno trajanje.

Poslove koji nisu vremenski kritični, koji neće izazvati veće probleme ako zakažu, koji se izvode u običnim sustavima se (u OS-u) označuju kao *obični* ili *nekritični*. Poslove koji jesu vremenski kritični, čija greška ili kasna reakcija može imati velike posljedice se označuju kao *kritičnima*. Operacijski sustavi najčešće omogućuju različite načine raspoređivanja: jedne za kritične poslove i druge za nekritične. Operacijski sustavi pripremljeni za SRSV-e, osim ostalih potrebnih svojstava imaju i vrlo dobru podršku raspoređivanju kritičnih dretvi, dok operacijski sustavi koji nisu posebice pripremljeni za SRSV-e optimiraju neke druge kriterije i u pogledu raspoređivanja poslova.

Pri ostvarenju sustava, jedan zadatak se preslikava u jednu dretvu te se stoga u nastavku koristi termin *dretva* umjesto *zadatka*, odnosno govori se o *raspoređivanju dretvi*. U nastavku su prikazani uobičajeni načini raspoređivanja dretvi ostvareni u operacijskim sustavima.

5.1. POSIX i Linux sučelja

POSIX (engl. *The Portable Operating System Interface*) je zajednički naziv za skupinu IEEE normi kojima se definira sučelja koja operacijski sustavi trebaju pružati programima, a radi njihove prenosivosti [POSIX]. Prenosivost programa je glavni razlog nastajanja POSIX-a i sličnih normi. U početku su ciljani operacijski sustavi bile razne inačice UNIX-a, ali se kasnije sučelje počelo širiti tako da obuhvaća i sustave za rad u stvarnom vremenu.

POSIX ostvaruju mnogi operacijski sustavi, pogotovo oni predviđeni za sustave za rad u stvarnom vremenu, najčešće radi omogućavanja prijenosa postojećih programa pripremljenih za druge sustave. U kontekstu SRSV-a POSIX definira nekoliko načina raspoređivanja (klase dretvi):

- `SCHED_FIFO` – prema prioritetu pa po redu prispijeća
- `SCHED_RR` – prema prioritetu pa kružnom podjelom vremena
- `SCHED_SPORADIC` – prema prioritetu, sporadični poslovi
- `SCHED_OTHER` – raspoređivanje nekritičnih dretvi.

Na promjene i proširenje POSIX-a utječu mnogi dionici, posebice oni koji se bave izgradnjom operacijskih sustava. Stoga će u nastavku pored navedenih načina raspoređivanja biti opisani i dodatni načini trenutno ostvareni 'samo' u Linux jezgri. Uz gornje načine, uz izuzetak načina `SCHED_SPORADIC` koji nije ostvaren, u Linuxu su dodatno ostvareni:

- `SCHED_DEADLINE` – raspoređivanje prema rokovima
- `SCHED_BATCH` – raspoređivanje nekritičnih dugotrajnih dretvi
- `SCHED_IDLE` – raspoređivanje najmanje bitnih dretvi.

U nastavku je najprije prikazano sučelje za postavljanje načina raspoređivanja i dodatnih parametara uz odabrane načine. S obzirom na to da većina načina koristi prioritete, u sučelja su ugrađene i funkcije koje upravljaju njime.

Isječak kôda 5.1. Postavljanje načina raspoređivanja i ostalih parametara

```
int pthread_setschedparam(pthread_t thread,
                          int policy,
                          const struct sched_param *param);
```

Isječak kôda 5.2. Postavljanje prioriteta dretvi

```
int pthread_setschedprio(pthread_t thread,
                         int prio);
```

Ekvivalentne funkcije na razini procesa su `sched_setscheduler` i `sched_setparam` (s istim ili ekvivalentnim parametrima).

Ponekad je jednostavnije prije stvaranja nove dretve definirati njene parametre za raspoređivanje.

Isječak kôda 5.3. Stvaranje nove dretve

```
int pthread_create(pthread_t *thread,
                   const pthread_attr_t *attr,
                   void *(*start_routine)(void*),
                   void *arg);
```

Drugi parametar funkcije (`attr`) definira atribute za novu dretvu te ga je potrebno postaviti prema željenim svojstvima nove dretve, prije stvaranja nove dretve.

Isječak kôda 5.4. Postavljanje parametara raspoređivanja za novu dretvu

```
int pthread_attr_init(pthread_attr_t *attr);
int pthread_attr_setinheritsched(pthread_attr_t *attr,
                                 int inheritsched);
int pthread_attr_setschedpolicy(pthread_attr_t *attr,
                                int policy);
int pthread_attr_setschedparam(pthread_attr_t *attr,
                               const struct sched_param *param);
```

Preko `pthread_attr_setinheritsched` se definira da li nova dretva nasljeđuje parametre raspoređivanja od dretve koja ju stvara (kada je drugi parametar `PTHREAD_INHERIT_SCHED`) ili ih treba zasebno postaviti (kada je drugi parametar `PTHREAD_EXPLICIT_SCHED`).

Način raspoređivanja postavlja se preko `pthread_attr_setschedpolicy`. Parametri tog načina (npr. prioritet) postavljaju se preko sučelja `pthread_attr_setschedparam`.

Prioritet dretvi se može promijeniti i pod utjecajem sinkronizacijskih mehanizama. To je objašnjeno uz opis sinkronizacijskih mehanizama u 7.5.

Stvaranje dretvi koje se raspoređuju metodama `SCHED_FIFO`, `SCHED_RR`, `SCHED_SPORADIC` i `SCHED_DEADLINE` zahtjeva povlaštenog korisnika (administratora) budući da njegove dretve mogu u potpunosti istisnuti sve druge dretve, pa čak i one operacijskog sustava.

U nastavku su opisani navedeni načini raspoređivanja definirani gornjim sučeljima.

5.2. Raspoređivanje dretvi prema prioritetu

Većina operacijskih sustava pripremljena ili prilagođena za sustave za rad u stvarnom vremenu zapravo koristi samo jedan način raspoređivanja – raspoređivanje prema prioritetu. Zato je način dodjele prioriteta dretvama najčešće prema postupku mjere ponavljanja. Odstupanja od tog postupka se koriste kada različite dretve obavljaju poslove različita značaja. Tada arhitekt sustava može nekim dretvama pridijeliti i veći ili manji prioritet od onog koji bi dretva dobila prema postupku mjere ponavljanja.

Samo raspoređivanje – određivanje trenutne dretve za izvođenje obavlja se pri radu sustava tako da se u svakom trenutku među dretvama spremnim za izvođenje (*pripravne dretve*) odabire ona najvećeg prioriteta (koja tada postaje *aktivna dretva*). Dretve koje nisu spremne za izvođenje (*blokirane dretve*) se ne razmatraju pri raspoređivanju.

S obzirom na to da postoji mogućnost da u nekom trenutku trenutno najveći prioritet nema samo jedna pripravna dretva već više njih, mora se koristiti i dodatni kriterij pomoću kojeg će se odabrati samo jedna dretva. Najčešće korišteni dodatni kriteriji su: prema redu prispijeća (engl. *first in first out – FIFO*) te podjela procesorskog vremena – kružno posluživanje (engl. *round robin – RR*). S obzirom na to da je prvi kriterij uvijek prioritet, takvi postupci u POSIX-u raspoređivanja dobivaju ime prema drugom kriteriju.

1. `SCHED_FIFO` – raspoređivanje prema prioritetu pa po redu prispijeća
2. `SCHED_RR` – raspoređivanje prema prioritetu pa kružnom podjelom vremena.

Slika 5.1. prikazuje mogući izgled strukture podataka raspoređivača koji koristi prioritet za raspoređivanje dretvi. Odabir aktivne dretve obavlja se među pripravnim dretvama najvećeg prioriteta, među dretvama A i B. S obzirom na to da je dretva A prva u listi ona će biti odabrana

kao aktivna. Ako je drugi kriterij FIFO, dretva A će se izvoditi dok ne završi ili dok se ne blokira. Ako je drugi kriterij RR onda će dretvu A u njenom izvođenju prekinuti raspoređivač nakon što je ona "potrošila" svoj dodijeljeni dio procesorskog vremena (kvant). Dretva A će tada biti stavljena na kraj reda dretvi s istim prioritetom, tj. iza dretve B. Iduća aktivna dretva bit će dretva B.

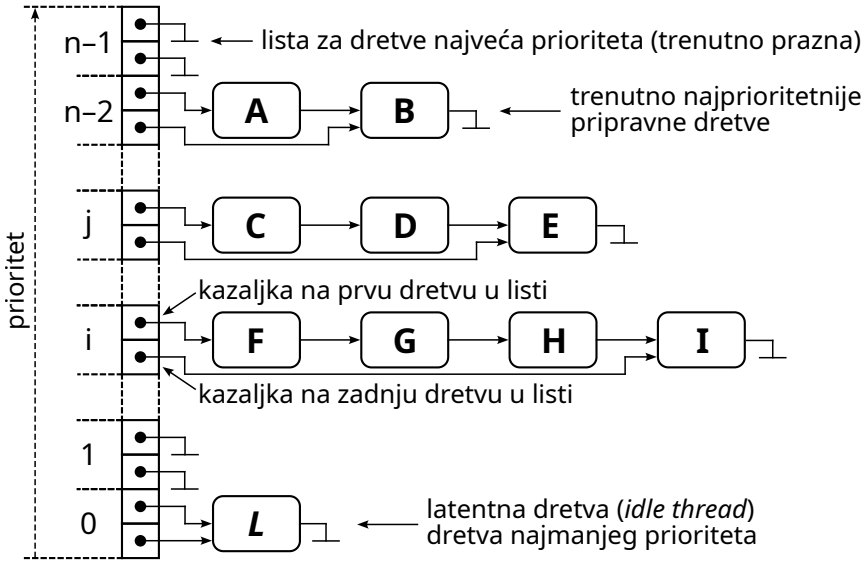

Slika 5.1. Primjer strukture podataka jezgre za raspoređivanje prema prioritetu

U višeprocesorskim sustavima red pripravnih dretvi (koje se raspoređuju) može biti ostvaren kao na slici 5.1., ali i drukčije. Kod jednog od pristupa se za svaki procesor stvara poseban red pripravnih. Razlog ovakve podjele je u efikasnijem korištenju priručna spremnika procesora (engl. *hot cache*). Tada postaje potrebno osigurati da se uvijek izvode dretve najveća prioriteta. Ponekad će to zahtjevati "guranje" dretvi u druge redove pripravnih dretvi ili posizanje za dretvama iz redova drugih procesora. Primjerice, kada aktivna dretva A na procesoru I omogući nastavak drugoj dretvi B nastavak svog rada, tada se B može gurnuti procesoru J ako on izvodi dretvu C čiji je prioritet manji od dretvi A i B, odnosno i od svih drugih aktivnih dretvi. Slično je i kada neka dretva završi s radom ili se blokira: tada je potrebno odabrati pripravnu dretvu najveća prioriteta među svim pripravnim dretvama – ne samo iz reda procesora koji je sada postao slobodan. U ovom se slučaju radi o "povlačenju" dretve iz reda pripravnih dretvi drugih procesora. Opisani postupci koriste se pri raspoređivanju dretvi u Linux-u.

Slika 5.2. prikazuje primjere raspoređivanja korištenjem prioriteta, kružnog posluživanja te događaja povezanih sa sinkronizacijskim funkcijama.

5.3. Raspoređivanje prema rokovima

Raspoređivanje prema rokovima je rijetko podržani način raspoređivanja dretvi, čak i među operacijskim sustavima za rad u stvarnom vremenu. U sustavima u kojima jest podržano takvo raspoređivanje, mehanizam njegova korištenja je takav da se dretva označi kao periodička, sa zadanom periodom kojom se dretva budi i pokreće.

Periodičke dretve se mogu prikazati pseudokodom prema primjeru 5.5.

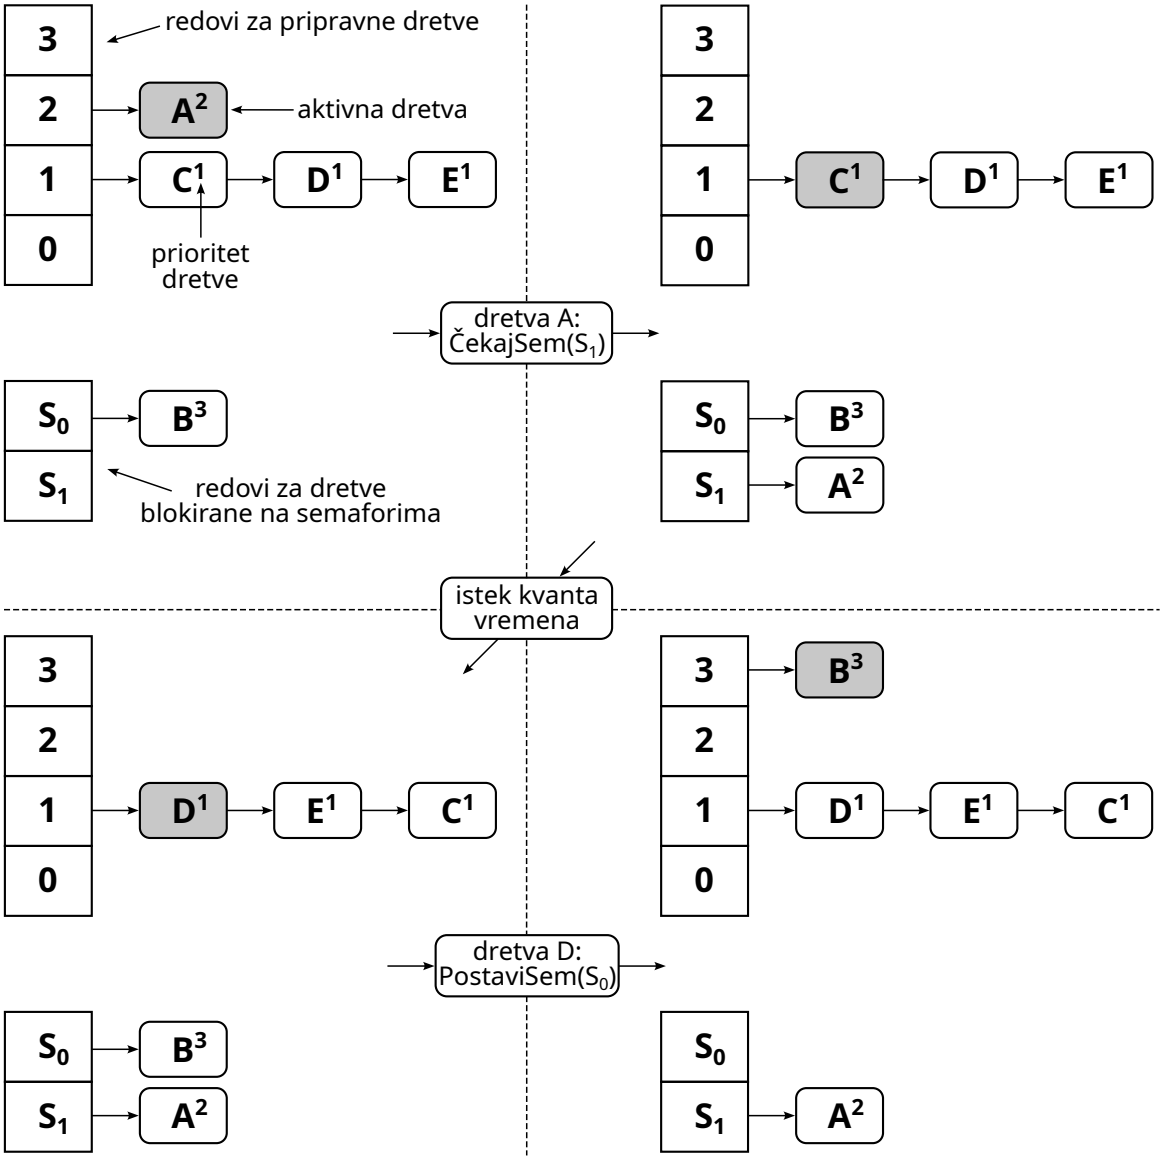

Slika 5.2. Primjeri raspoređivanja prema prioritetu i podjeli vremena

Isječak kôda 5.5. Načelni pseudokod periodičke dretve

```
periodička_dretva
   ponavljaj
      odradi_periodički_posao
      odgodi_izvođenje(ostatak_periode)
```

Pseudokod takvih dretvi treba proširiti odgovarajućim pozivima. Uobičajeno sučelje koje nude operacijski sustavi koji podržavaju takvo raspoređivanje prikazano je na primjeru 5.6.

Isječak kôda 5.6. Uobičajena sučelja za raspoređivanje prema rokovima

```
periodička_dretva
   označi_periodičnost(period)
   ponavljaj
      čekaj_početak_periode()
      odradi_periodički_posao
```

Operacijski sustav nudi sučelje koje je u primjeru prikazano funkcijama `označi_periodičnost` i `čekaj_početak_periode`.

5.3.1. Raspoređivanje prema rokovima kod Linuxa

Linux jezgra od inačice 3.14 (ožujak 2014.) donosi podršku za ovaj način raspoređivanja pod imenom *Sporadic task model deadline scheduling* s oznakom `SCHED_DEADLINE`. Parametri takve dretve su:

- T – perioda ponavljanja (`sched_period`)
- C – potrebno vrijeme izvođenja unutar periode (`sched_runtime`)
- d – relativni rok u odnosu na početak periode (`sched_deadline`)

uz ograničenje: $C \leq d \leq T$.

Pri stvaranju nove dretve ovakva načina raspoređivanja provjerava se rasporedivost sustava dretvi koje se već raspoređuju prema `SCHED_DEADLINE` uz dodatak opterećenja ove dretve. Ako bi ova dretva narušila rasporedivost, jezgra će odbiti zahtjev za stvaranjem takve dretve ili pretvaranje postojeće u ovakvu. S obzirom na to da dretve koje se raspoređuju sa `SCHED_DEADLINE` istiskuju sve druge dretve, ovakvim jednostavnim provjerama osigurava se rasporedivost svih dretvi koje se raspoređuju ovim načinom, a koje poštuju nametnuta ograničenja vremena izvođenja unutar periode. Da poneka dretva ne bi ugrozila ostale koje se raspoređuju prem `SCHED_DEADLINE`, dodatno se koristi postupak rezervacije poslužiteljskog vremena (engl. *Constant Bandwidth Server – CBS*). Naime, ako pojedina dretva od početka periode (njena aktiviranja) 'potroši' zadano vrijeme izvođenja (a prije blokiranja ili poziva `sched_yield()` kojim se označava kraj računanja u periodi) ona je potrošila svoje 'rezervirano vrijeme' u ovoj periodi. Stoga ona u tom trenutku može biti i istisnuta, ako se za to pojavi potreba od ostalih dretvi u sustavu. Obično se to ostvaruje na način da se njen rok poveća za jednu periodu ('koristi se i njena iduća perioda') te će na red prije njenog nastavka doći ostale dretve s bližim kranjim trenutkom završetka. Pregled ovog i ostalih načina raspoređivanja u Linux jezgri detaljnije je opisan na [Linux scheduling].

5.3.2. Raspoređivanje sporadičnih poslova

Osiguranje unaprijed definiranog procesorskog vremena pojedinom poslu trebalo bi omogućiti i sporadično raspoređivanje. Raspoređivanje `SCHED_SPORADIC` je noviji postupak raspoređivanja (vrlo rijetko još podržan u operacijskim sustavima, primjerice [QNX, 6.3]), pripremljen za periodičke dretve, kod kojih dretva tijekom svake svoje periode treba određeno procesorsko vrijeme. Raspoređivač bi joj to vrijeme trebao dodijeliti uz viši prioritet. Ako u tom vremenu ne obavi svoj periodički posao (nije gotova), prioritet joj se smanjuje tako da suviše ne utječe na ostale dretve sustava. Parametri tog raspoređivanja su:

- period obnavljanja prioriteta (engl. *replenishment period*),
- povlašteno vrijeme rada (engl. *initial budget*),
- povlašteni prioritet (engl. *high priority*) te
- smanjeni prioritet (engl. *lower priority*).

Primjer rada ovog raspoređivača prikazuje slika 5.3.

Sporadično raspoređivanje je namijenjeno periodičkim poslovima većeg prioriteta koji uglavnom kratko obave svoje operacije (u svakoj pojavi/periodi). Međutim, ponekada se može

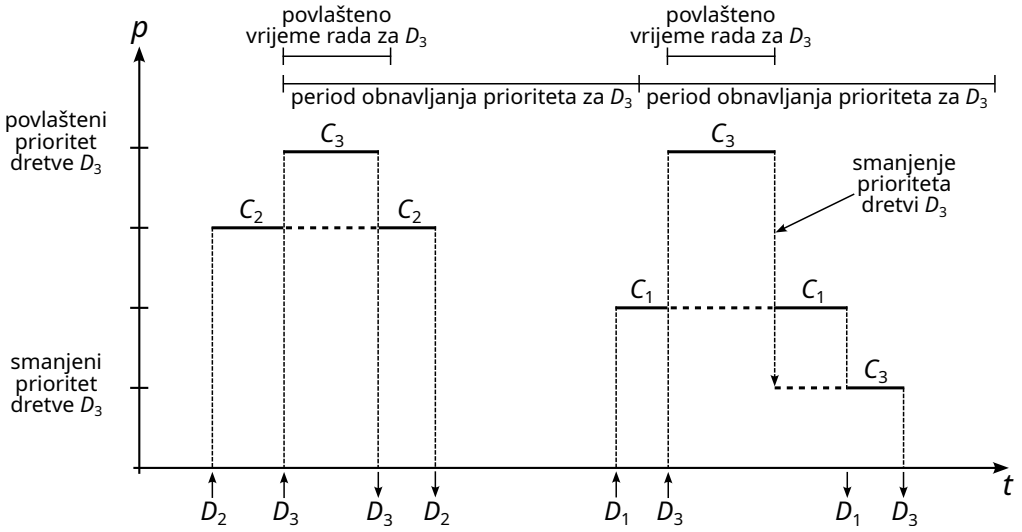

Slika 5.3. Primjer sporadičnog raspoređivanja

dogoditi da posao zahtjeva malo više vremena. Da se u tim slučajevima ne bi narušili ostali poslovi, `SCHED_SPORADIC` će za te dulje obrade smanjiti prioritet dretvi, nakon početnog povlaštenog vremena s većim prioritetom.

Primjer 5.1. Primjer korištenja POSIX-a

U ovome primjeru se koriste načini raspoređivanja `SCHED_FIFO` i `SCHED_RR`. Ispis prioriteta dretvi obavlja se unutar kritična odsječka da ne bi došlo do preklapanja u ispisu.

```
#include <stdio.h>
#include <stdlib.h>
#include <sched.h>
#include <pthread.h>

#define BROJ_DRETVI 5
static pthread_mutex_t monitor = PTHREAD_MUTEX_INITIALIZER;

static void ispisi_postavke_rasporedjivanja_dretve(long id)
{
    int nacin_rasporedjivanja;
    struct sched_param prioritet;

    pthread_mutex_lock(&monitor);
    pthread_getschedparam(pthread_self(),
        &nacin_rasporedjivanja, &prioritet);
    printf("Dretva %ld: nacin_rasporedjivanja=%d, prioritet=%d\n",
             id, nacin_rasporedjivanja, prioritet.sched_priority);
    pthread_mutex_unlock(&monitor);
}

static void *posao_dretve(void *param)
{
    ispisi_postavke_rasporedjivanja_dretve((long) param);
    return NULL;
}

int main ()
{
```

```
    long min, max, pocetni_prioritet, i, nacin_rasporedjivanja;
    pthread_attr_t attr;
    pthread_t tid[BROJ_DRETVI];
    struct sched_param prioritet;

    ispisi_postavke_rasporedjivanja_dretve(0);

    /*! Dohvati raspon prioriteta za zadani način raspoređivanja */
    nacin_rasporedjivanja = SCHED_FIFO;
    min = sched_get_priority_min(nacin_rasporedjivanja);
    max = sched_get_priority_max(nacin_rasporedjivanja);

    /* Postavi način raspoređivanja i prioritet početnoj dretvi */
    pocetni_prioritet = prioritet.sched_priority = (min + max) / 2;
    if (pthread_setschedparam(pthread_self(),
        nacin_rasporedjivanja, &prioritet))
    {
        perror("Greska: pthread_setschedparam (dozvole?)");
        exit (1);
    }

    ispisi_postavke_rasporedjivanja_dretve(0);

    /* Postavke raspoređivanja za nove dretve */
    pthread_attr_init(&attr);
    pthread_attr_setinheritsched(&attr, PTHREAD_EXPLICIT_SCHED);
    nacin_rasporedjivanja = SCHED_RR;
    pthread_attr_setschedpolicy(&attr, nacin_rasporedjivanja);

    /* Stvaranje novih dretvi */
    for (i = 0; i < BROJ_DRETVI; i++) {
        prioritet.sched_priority = (min + i) % pocetni_prioritet;
        pthread_attr_setschedparam(&attr, &prioritet);
        if (pthread_create(&tid[i], &attr, posao_dretve, (void *) (i+1))) {
            perror("Greska: pthread_create");
            exit (1);
        }
    }

    /* Čekaj da stvorene dretve završe s radom */
    for (i = 0; i < BROJ_DRETVI; i++)
        pthread_join(tid[i], NULL);

    return 0;
}

/* Primjer pokretanja: (na jednoprocesorskom sustavu !!!)
$ gcc scheduling.c -pthread -Wall
$ sudo ./a.out
Dretva 0: nacin_rasporedjivanja=0, prioritet=0
Dretva 0: nacin_rasporedjivanja=1, prioritet=50
Dretva 5: nacin_rasporedjivanja=2, prioritet=5
Dretva 4: nacin_rasporedjivanja=2, prioritet=4
Dretva 3: nacin_rasporedjivanja=2, prioritet=3
Dretva 2: nacin_rasporedjivanja=2, prioritet=2
Dretva 1: nacin_rasporedjivanja=2, prioritet=1
*/
```

Iz ispisa prikazanome uz kod vidi se da se stvorene dretve izvode prema prioritetu: naprije ona prirriteta 5, a najzadnja ona prioriteta 1, iako je redoslijed njihova pokretanja bio obrnut. Međutim, na višeprocesorskim sustavima to ne mora biti tako. Naime, u prikazanome

primjeru je posao svake dretve samo ispis parametara raspoređivanja što je vrlo kratko, kraće od stvaranja nove dretve, stoga bi ona dretva manjeg prioriteta mogla stići obaviti svoje prije pojave dretve većeg prioriteta koja bi ju inače istisnula.

5.4. Raspoređivanje nekritičnih dretvi

Pri raspoređivanju nekritičnih dretvi mogu se koristiti razna načela:

- pravedna podjela procesorskog vremena
- veća učinkovitost sustava
- veća procesorska iskoristivost
- veći broj završenih dretvi
- minimizacija čekanja u redovima
- kraće vrijeme odziva interaktivnih dretvi
- optimizacija korištenja priručnih spremnika.

Načelo pravednosti omogućuje podjednake dijelove procesorskog vremena svim dretvama u sustavu. Uz višu iskoristivost procesora, više će se posla obaviti, sustav će biti učinkovitiji. Načelom većeg broja završenih dretvi sustav se brže oslobodi većeg broja dretvi, a postiže se tako da se favoriziraju kratke dretve. Minimizacijom čekanja u redovima smanjuje se prosječno vrijeme koje dretve provedu u redu prije nego li su bar dijelom odradile svoj posao. Interaktivne dretve upravljaju s korisničkim sučeljem ili UI jedinicama te tako utječu na percepciju sustava kao sporog ili brzog. Npr. brza reakcija na zahtjeve korisnika stvara dojam da je sustav brz. U sustavima s više procesora/procesorskih jedinki načelo optimiranja korištenja priručnih spremnika nalaže raspoređivaču da nastoji zadržati dretvu na istom procesoru. Naime, u sukcesivnim izvođenjima (nakon zamjene s drugim dretvama) takva dretva može pronaći svoje podatke još uvijek u priručnom spremniku procesora i time smanjiti vrijeme njihovog dohvata te općenito gledajući, povećati učinkovitost sustava.

U operacijskim sustavima opće namjene dretve koji nisu vremenski kritične uglavnom se raspoređuju načelom pravedne podjele procesorskog vremena. Dretve i tu imaju atribut prioriteta, ali se prioritet koristi za određivanje koliko će procesorskog vremena te dretve dobiti (izračun se obavlja uzimajući sve pripravne dretve i njihove prioritete).

Uobičajeni princip raspoređivanja koji se koristi za takve dretve obično se opisuje algoritmom višerazinsko raspoređivanje s povratnom vezom (engl. *multilevel feedback queue – MFQ*). Ciljevi koje to raspoređivanje nastoji ostvariti su:

- dati prednost dretvama s kratkim poslovima
- dati prednost dretvama koje koriste ulazno-izlazne naprave
- na osnovi rada dretve ustanoviti u koju skupinu dretva pripada te ju prema tome dalje raspoređivati.

Duge dretve, tj. dretve koje su procesorski intenzivne, koje trebaju puno procesorskog vremena (koje bi cijelo vrijeme koristile procesor) se žele potisnuti. Naime, takve dretve ionako duže traju, te se očekuje da će kasnije biti gotove te će njihova kratka odgoda zbog izvođenja drugih dretvi manje utjecati na sustav nego odgoda kratkih dretvi, koje, primjerice upravljaju korisničkim sučeljem i čija reakcija mora biti promptna, inače se kod korisnika stvara dojam sporosti sustava.

Višerazinsko raspoređivanje s povratnom vezom može se opisati skupom pravila ponašanja raspoređivača nad skupom dretvi koje su složene prema trenutnim prioritetima u redove prema redu prispijeća (slično slici 5.1.).

1. Uvijek se raspoređuje prva dretva iz reda najvećeg prioriteta (najviši neprazni red).
2. Procesor se dretvi dodjeljuje za određeni interval vremena – kvant vremena.
3. Ako dretva završi u tom kvantu, ona napušta sustav (ne razmatra se više u postupku raspoređivanja).
4. Ako se dretva pri svom izvođenju blokira, miče se iz reda pripravnih, ali se kasnije, pri odblokiranju stavlja u isti red pripravnih dretvi iz kojeg i otišla ('zadržava prioritet'), ili ovisno o vremenu provedenom u blokiranom stanju, čak se postavlja i u više redove (podiže joj se prioritet).
5. Ako se dretva izvodi cijeli kvant i nije gotova, onda ju raspoređivač prekida i miče u red niže (smanjuje joj prioritet za jedan).
6. Postupak se ponavlja dok god ima pripravnih dretvi i dok one ne dođu do najnižeg reda (reda najmanjeg prioriteta). U tom redu se dretve poslužuju podjelom vremena.
7. Kada u sustav dođe nova dretva, ona se stavlja u najviši red (najprioritetniji red), na kraj tog reda.

Kvant vremena može biti različit ovisno o prioritetu, npr. za veće prioritete manji, a za manje veći.

Opisani postupak vrlo brzo procjenjuje dretvu: je li ona spada u kategoriju kratkih ili dugih. Ako je kratka, ostaje joj prioritet, a ako je duga prioritet joj pada tijekom izvođenja.

Višerazinsko raspoređivanje s povratnom vezom se ne ostvaruje u operacijskim sustavima upravo prema prikazanom postupku, ali se sličnim pristupima nastoje ostvariti navedena načela.

U nastavku je ukratko opisano raspoređivanje dretvi u operacijskim sustavima zasnovanim na Linux jezgri te sustavima zasnovanim na porodici operacijskih sustava Microsoft Windows.

Primjer 5.2. Raspoređivači ugrađeni u Linux jezgru

Operacijski sustavi zasnovani na Linux jezgri podržavaju raspoređivanje kritičnih i nekritičnih dretvi zasebnim raspoređivačima. Za kritične dretve mogu se odabrati načini raspoređivanja `SCHED_FIFO`, `SCHED_RR` i `SCHED_DEADLINE` (opisani prethodno), a za nekritične načini `SCHED_OTHER`, `SCHED_BATCH` i `SCHED_IDLE`. Prioriteti kritičnih dretvi kreću se od 1 do 99 (veći broj označava veći prioritet).

Nekritične dretve će dobiti procesorsko vrijeme tek kada nema niti jedne kritične dretve u redu pripravnih. Iznimno, od Linux jezgre 2.6.25 moguće je rezervirati dio procesorskog vremena i za nekritične dretve. Uobičajeno je to postavljeno na 5 % procesorskog vremena. Navedena rezervacija omogućava administratoru da pokrene zaustavljanje kritične dretve koja ima grešku (npr. beskonačnu petlju i koristila bi svo procesorsko vrijeme).

Dretve koje spadaju u klase `SCHED_OTHER`, `SCHED_BATCH` i `SCHED_IDLE` imaju osnovni prioritet postavljen na nulu (manji od najmanjeg za kritične dretve), ali za međusobnu usporedbu (raspoređivanje) koriste drugu vrijednost, takozvanu *razinu dobrote* (engl. *nice level*) koja se kreće od -20 (najveća) do $+19$ (najmanja). Dobrote ispod nule može postavljati samo administrator (korisnik *root*). Dobrota dretve utječe na to koliko će procesorskog vremena dretva dobiti u odnosu na ostale dretve različite dobrote. Primjerice, dretva s razinom dobrote q trebala bi dobiti od 10 do 15 % više procesorskog vremena od dretve razine $q + 1$.

Načini raspoređivnja `SCHED_OTHER` i `SCHED_BATCH` su slični, jedino što će raspoređivač uvijek pretpostaviti da je dretva u klasi `SCHED_BATCH` duga dretva i zbog toga biti u nešto lošijem položaju od ostalih dretvi (u klasi `SCHED_OTHER`).

Dretve u klasi `SCHED_IDLE` imaju najmanju dobrotu i neće se izvoditi dokle god ima drugih dretvi koje nisu u istoj klasi.

Od inačice Linux jezgre 2.6.23 za raspoređivanje nekritičnih dretvi (`SCHED_OTHER`, `SCHED_BATCH` i `SCHED_IDLE`) koristi se raspoređivač naziva *potpuno pravedan raspoređivač* (engl. *completely fair scheduler – CFS*). Korištenjem izračunatog virtualnog vremena koje pripada pojedinoj dretvi i stvarno dodijeljenog vremena, tj. razlike tih vremena izgrađuju se crveno-crna stabla s pripravnim dretvama te se za aktivnu odabire ona dretva kojoj sustav najviše duguje (s najvećom razlikom).

Za prikaz osnovne ideje CFS-a razmotrimo jednostavan primjer. Neka se u sustavu u početnom trenutku nalazi pet dretvi $\{D_1, \ldots, D_5\}$ iste razine dobrote. Raspoređivač će odabrati jednu, recimo D_1, i njoj dati kvant vremena T_q. Nakon što taj kvant istekne, raspoređivač će ažurirati virtualna vremena koja pripadaju pojedinim dretvama. U tom intervalu svaka od dretvi je trebala dobiti jednaki dio virtualnog vremena, tj. $T_q/5$. S obzirom na to da se samo D_1 izvodila, jedino će se njoj povećati dodijeljeno vrijeme za T_q što će uzrokovati pomak te dretvu u stablu – ona više neće biti zajedno s ostalima već zadnja u ovom trenutku. Zato će raspoređivač u idućem trenutku odabrati neku drugu dretvu $\{D_2, \ldots, D_5\}$ kao aktivnu.

Primjer 5.3. Raspoređivanje u operacijskim sustavima Microsoft Windows

Raspoređivanje u porodicama operacijskih sustava Microsoft Windows (NT, 2000, XP, 2003, Vista, 7, 8, 10, 11) obavlja se korištenjem prioriteta dretvi. Prioritet dretve računa se na osnovu prioritetne klase procesa i prioritetne razine dretvi, prema tablicama 5.1. i 5.2. Imenima klase procesa iz tablice treba dodati `_PRIORITY_CLASS` a imenima razine dretvi prefiks `THREAD_PRIORITY_`.

Tablica 5.1. Prioritetne klase procesa

oznaka klase
IDLE (ID)
BELOW_NORMAL (BN)
NORMAL (N)
ABOVE_NORMAL (AN)
HIGH (H)
REALTIME (RT)

Tablica 5.2. Prioritetne razine dretvi

oznaka razine
IDLE (ID)
LOWEST (L)
BELOW_NORMAL (BN)
NORMAL (N)
ABOVE_NORMAL (AN)
HIGHEST (H)
TIME_CRITICAL (TC)

Tablice 5.3. i 5.4. prikazuju dodjeljivanje prioriteta na osnovu prioritetnih klasa i razina.

Tablica 5.3. Izračun prioriteta za normalne dretve (ID, BN, N, AN, H)

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
ID	ID	L	BN	N	AN	H									TC
BN	ID			L	BN	N	AN	H							TC
bN	ID				L	BN	N	AN	H						TC
fN	ID						L	BN	N	AN	H				TC
AN	ID							L	BN	N	AN	H			TC
H	ID										L	BN	N	AN	H,TC

Prioritet 0 (najniži prioritet) rezerviran je za posebne dretve operacijskog sustava (npr. dretve koje brišu oslobođene stranice u postupku upravljanja spremnikom straničenjem).

Tablica 5.4. Izračun prioriteta za kritične dretve (RT)

16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
ID	−7	−6	−5	−4	−3	L	BN	N	AN	H	3	4	5	6	TC

Raspoređivanje kritičnih dretvi (klasa `REALTIME_PRIORITY_CLASS`) se ponešto razlikuje od ostalih klasa, odnosno raspoređivanje je identično prethodno opisanom načinu `SCHED_RR`, uz raspon prioriteta od 16 do 31.

Raspoređivanje nekritičnih dretvi obavlja se korištenjem njihovih prioriteta – dretve najvećeg prioriteta se odabiru za izvođenje, slično `SCHED_RR`, ali uz iznimke. Prve iznimke su dretve procesa u klasi `NORMAL_PRIORITY_CLASS` (`N`). Proces koji je trenutno u fokusu

korisnika (engl. *foreground process*) dobiva malo povećanje prioriteta (prefiks `f` u tablici 5.3.) u odnosu na procese koji nisu u fokusu (prefiks `b`). Druge iznimke su pripravne dretve koje dugo nisu dobile ništa procesorskog vremena (izgladnjele dretve). Njima raspoređivač povremeno dodijeljuje dio procesorskog vremena da izbjegne njihovo potpuno izgladnjivanje i također da ublaži problem inverzije prioriteta (više o inverziji prioriteta u poglavlju 7.5.).

Tablica 5.5. Usporedba prikazanih načina raspoređivanja

Raspoređivač	**Tip dretvi**	**Parametri**	**Operacijski sustavi**
SCHED_FIFO	kritične	prioritet	Linux
SCHED_RR	kritične	prioritet	Linux, Windows (p:[16-31])[a]
SCHED_SPORADIC	kritične	viši i niži prioritet, period, povlašteno vrijeme rada u periodi	QNX
SCHED_DEADLINE	kritične	period, relativni rok, najveće potrebno vrijeme u periodi	Linux
SCHED_OTHER	nekritične	razina dobrote	Linux
SCHED_RR[a]	nekritične	prioritet	Windows (p:[0-15])[a]

[a]Raspoređivač dretvi na operacijskim sustavima Windows nema posebno ime, ali je najbliži SCHED_RR načinu, tj. koristi prioritet za raspoređivanje, ali uz već opisane iznimke.

5.5. Upravljanje poslovima u uređajima napajanim baterijama

Mnogi su računalni sustavi (računala) napajana iz baterija, bez priključka na izvor stalne energije (na električnu mrežu). U takvim je sustavima osobito bitno osigurati željeni period samostalnog rada. Dok se za prijenosna računala, tablete i pametne telefone to vrijeme mjeri satima, za neke druge to mogu biti dani, tjedni, mjeseci pa i godine! Radi omogućavanja navedena načina rada treba prilagoditi i sklopovlje i programe koji će biti i manje zahtjevni i koji će znati iskoristiti posebnosti sklopovlja.

Veliki potrošač energije jest procesor jer najčešće on radi na najvećoj frekvenciji. Stoga se on pokušava izvesti u posebnoj tehnologiji manje potrošnje. Mogućnosti upravljanja takvim procesorom radi uštede energije uglavnom spadaju u sljedeće kategorije:

- prilagodljiva frekvencija rada – manja kada je računalo napajano baterijom ili nema potrebe za većom procesorskom snagom
- zaustavljanje procesora posebnim instrukcijama kada nema nikakva posla (npr. pri izvođenju latentne/idle dretve)
- zaustavljanje nepotrebnih jezgri u višejezgrenome procesoru.

Za ostale komponente računala mogu vrijediti ista načela kao i za procesor: izvedba u tehnologiji manje potrošnje, mogućnost zaustavanja rada naprave te rada u načinu sa smanjenom potrošnjom.

Operacijski sustav treba poznavati mogućnosti naprava i koristiti one načine uštede energije koji naprave pružaju. Ovdje spadaju i isključivanje zaslona, postavljanje u stanje niske potrošnje ili čak i gašenje računala nakon nekog intervala nekorištenja.

Razni tipovi računala se koriste na razne načine.

Prijenosno računalo je zapravo zamjena za stolno te nasljeđuje njegova svojstva i načine korištenja. To zapravo znači da korisnik pokreće neke programe koje operacijski sustav raspoređuje prema utvrđenim kriterijima, primjerice, prema prioritetu.

Pametni telefon i tablet računalo se naizgled koriste na isti način. Međutim, oni su u začetku zamišljeni za jednog korisnika i jedan program s kojim korisnik u jednom trenutku izravno komunicira, stoga je i sama unutarnja arhitektura tih sustava ponešto drukčija. Program koji komunicira s korisnikom je u tom trenutku najvažniji i njemu treba dati sva potrebna sredstva sustava, dok ostale treba zaustaviti. S obzirom na taj očekivani način rada, programi pisani za takve sustave imaju dio koda koji se izvodi dok je program aktivan (komunicira s korisnikom), dio koda koji se izvodi kada program prestaje biti aktivan, dio koda koji se izvodi kada program ponovno postaje aktivan i slično. Ako program treba izvoditi neke periodičke radnje i dok nije aktivan onda se on mora koristiti posebnim sučeljem operacijskog sustava za izvođenje tih periodičkih aktivnosti. Primjerice, slušanje glazbe zahtjeva periodički dohvat dijela skladbe, obradu tog dijela te prijenos prema zvučnom podsustavu računala koji će ga dalje prosljediti u pravom obliku do zvučnika.

Ostala ugrađena računala manje procesne snage prilagođavaju se svojoj funkciji. Najčešće to nisu računala za opću uporabu, s programima različite namjene, već služe samo za jednu ili do nekoliko namjena. U ovu klasu računala možemo ubrojiti i računala koja se sada nazivaju 'Internet stvari' (engl. *Internet of Things – IoT*), a za koje se predviđa da će u bliskoj budućnosti brojčano znatno nadmašiti sva ostala računala zajedno. Radi osiguravanja dugog rada takvih sustava potrebno je izdvojiti one komponente koje potencijalno troše najviše energije i prilagoditi njihov rad da se potrošnja smanji. S današnje perspektive to su dijelovi računala predviđeni za ostvarenje komunikacije za koje je za sada potrebna najveća energija ako bi željeli stalnu povezanost tih računala s ostalima ('na Internet'). Već i sada postoji nekoliko protokola koji omogućuju komunikaciju koja nije toliko zahtjevna kao dosadašnje tehnologije. Ipak, još uvijek se radi na osmišljavanju još boljih, tj. manje zahtjevnih protokola i tehnologija, koje bi omogućile još dulji rad takvih ugrađenih računala i sa samo povremenom povezanošću s ostalim računalima, npr. čak i ne izravno na mrežnu infrastrukturu već do nje preko ostalih sličnih računala, npr. bežične mreže osjetila (engl. *wireless sensor network – WSN*). Primjerice, ugrađeno računalo koje bi se moglo ugraditi u čovjeka (npr. ispod kože), a koje bi mjerilo temperaturu, krvni tlak, udio neke materije u krvi, pratilo rad srca i slično, trebalo bi biti što manje, u mogućnosti raditi što duže (mjereno u mjesecim/godinama!). S druge strane takvo bi računalo trebalo svoja mjerenja u nekim intervalima pokušati prosljediti prema drugom računalu koje bi ih pohranilo te možda napravilo i neke složenije analize. Osnovnu analizu bi možda moglo napraviti i ugrađeno računalo te poslati poruke upozorenja ako su očitani podaci problematični.

Ako se projektira ugrađeno računalo napajano baterijom, pored uobičajenih problema ostvarenja logičke i vremenske ispravnosti treba voditi računa i o samostalnom radu računala u predviđenom periodu njegova rada te koristiti i postupke kojim će se smanjiti potrošnja energije, a da bi se željena samostalnost mogla ostvariti. Odabir redoslijeda izvođenja raznih poslova/operacija će vjerojatno biti različit od do sada opisivanih postupaka koji nisu uzimali u obzir potrošnju energije.

Pitanja za vježbu 5

1. Usporediti postupke raspoređivanja koji se koriste za vremenski kritične poslove s onim poslovima koji nisu vremenski kritični.
2. Opisati postupke raspoređivanja: `SCHED_FIFO`, `SCHED_RR`, `SCHED_SPORADIC`, `SCHED_DEADLINE` i `SCHED_OTHER`.
3. Opisati kriterije i načela raspoređivanja običnih (vremenski nekritičnih) dretvi prema višerazinskom raspoređivanju s povratnom vezom (engl. *multilevel feedback queue – MFQ*).
4. Opisati postupke raspoređivanja podržane u operacijskim sustavima Linux te MS Windows.
5. U sustavu se javljaju dretve A, B, C i D. Dretva A ima najveći prioritet, slijede dretve B i C koje imaju jednaki prioritet, te dretva D koja ima najmanji prioritet. Dretva A se javlja u t=4. s, B u t=2. s, C u t=5. s te D u t=1. s. Svaka dretva treba 5 s procesorskog vremena. Sustav koristi raspoređivanje `SCHED_RR` (prioritet pa podjela vremena). Prikazati redoslijed izvođenja dretvi na procesoru dok se sve dretve ne obave do kraja.
6. U sustavu koji koristi posluživanje `SCHED_RR` pojavljuju se sljedeće dretve: (id_dretve, vrijeme_pojave, trajanje, prioritet) = { (1, 0, 6, 5), (2, 2, 6, 5), (3, 5, 6, 5), (4, 9, 5, 10), (5, 12, 2, 1) }. Veći broj predstavlja veći prioritet. Kvant vremena iznosi jednu jedinicu vremena (kućanski se poslovi zanemaruju). Prikazati redoslijed izvođenja dretvi na procesoru dok se sve dretve ne obave do kraja.
7. U nekom trenutku u sustavu se nalazi skup dretvi A, B, C i D. Dretve A i C raspoređuju se prema `SCHED_RR` a ostale B i D prema `SCHED_FIFO`. Prioriteti dretvi su: $p_A = 30$, $p_B = 30$, $p_C = 25$ te $p_D = 20$. Pokazati rad sustava dok sve navedene dretve ne završe, uz pretpostavku da svaka od navedenih dretvi treba još pedeset milisekudi te da (za dretve koje ga koriste) kvant vremena iznosi $T_q = 20$ ms.
8. Neki sustav koristi prioritetno raspoređivanje. Svake sekunde raspoređivač prolazi pripravne dretve te onim dretvama koje još nisu dobile procesorsko vrijeme (u zadnjoj sekundi, a pojavile su se u sustavu prije kraja te sekunde) procesor daje po dva kvanta vremena $T_q = 10$ ms. Uz pretpostavke da poslovi pojedinačno nikada ne traju dulje od 50 ms, da u sustavu nikad nema više od 10 poslova (poslovi se dinamički javljaju u sustav), koliko će u najgorem slučaju trajati prekid izvođenja neke dretve (istisnute zbog prioritetnijih)?

6. Upravljanje vremenom

Vremenska određenost je od presudnog značenja za SRSV-e. U dosadašnjim razmatranjima susreli smo se sa zahtjevima vremenske usklađenosti i kako ju na određene načine ostvariti. Međutim, nismo razmatrali svojstva stvarnih sustava i njihove mehanizme za korištenje vremena, nismo razmatrali probleme poput njihove preciznosti, stabilnosti te kako koristiti vrijeme u raspodijeljenim sustavima. U ovom poglavlju ukratko su prikazane neke od mogućnosti korištenja vremena ostvarive kroz POSIX sučelje današnjih operacijskih sustava.

Razmotrimo primjer odgode dretve za neki željeni interval vremena T prikazan na slici 6.1.

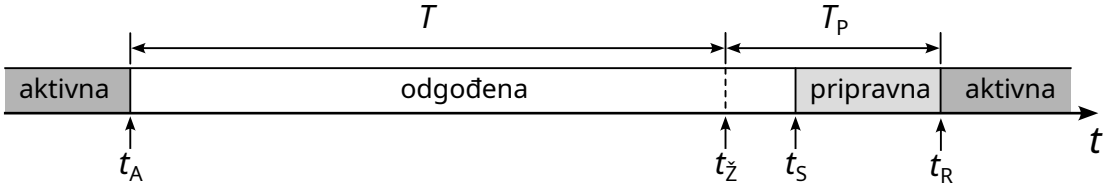

Slika 6.1. Stanje dretve pri odgodi

Dretva je odgodu tražila i dobila u trenutku t_A. Željeni interval odgode T bi dretvu trebao ponovno pokrenuti u trenutku $t_\check{\mathrm{Z}}$. Međutim, zbog granulacije svog sata operacijski sustav će to možda napraviti malo kasnije ili malo prije, u trenutku t_S. Iako probuđena u t_S, zbog mogućih drugih događaja u sustavu, primjerice obrade prekida ili prioritetnijih dretvi, dretva može krenuti i kasnije, u trenutku t_R. Od željenog trenutka nastavka rada do stvarnog početka rada može proći vrijeme T_P koje može biti i primjetno veliko u usporedbi s T. Zbog navedenog, potrebno je poznavati svojstva sustava i sučelja koja se koriste za ostvarenje željene vremenske usklađenosti.

6.1. Korištenje satnih mehanizama u operacijskim sustavima

Uz pretpostavku valjanog ostvarenja sustavskog sata u operacijskim sustavima, prije korištenja određenog sučelja ipak treba najprije razmotriti svojstva tog sučelja. Primjerice, je li preciznost zadovoljavajuća? Uobičajeno sustavi nude satne mehanizme kojima je najmanja jedinica jedna sekunda te mehanizme koji imaju znatno manju granulaciju, milisekunda, mikrosekunda ili nanosekunda. Čak i ovi precizniji mehanizmi trebaju se dodatno provjeriti u ciljanom sustavu, jer iako deklarirana jedinica može biti primjerice nanosekunda, stvarna granulacija može biti značajno veća, npr. milisekunda.

UNIX/POSIX sučelje u granulaciji sekunde, kao što su `sleep`, `time`, `alarm` očito nije prikladno za sustav u kojima je potrebna jedinica vremena ispod sekunde.

Sučelja koja koriste granulaciju ispod sekunde ima više. Neka od njih koriste mehanizam signala za aktivaciju, a druga ne.

6.1.1. Satovi sustava

Dva najznačajnija sata (u kontekstu SRSV-a) su:

1. `CLOCK_REALTIME` i
2. `CLOCK_MONOTONIC`.

Oba odbrojavaju u taktu stvarnog sata, ali samo prvi CLOCK_REALTIME predstavlja stvarno vrijeme, npr. iz njega se može odrediti da je trenutno vrijeme 12 sati i 35 minuta i 21 sekunda. Obzirom na tu povezanost, taj se sat može povremeno ažurirati, npr. dohvatom točnog vremena od udaljenog poslužitelja. Nekim dretvama je to potrebno ako pokreću svoje akcije u skladu s takvim satom (npr. u 11 sati i 30 minuta napravit to i to). Međutim, nekim drugim dretvama koje rade s relativnim vremenima (periodičke poslove) to može poremetiti aktivnosti. Primjerice, iduća aktivnost zbog ažuriranja vremena može biti pokrenuta prerano ili prekasno.

Sat CLOCK_MONOTONIC se ne može naknadno promijeniti, on nakon uključenja računala uvijek odbrojava te je zato prikladniji za neke procese koje promjena (ažuriranje) sata sustava može navesti na krive zaključke o protoku vremena.

Osim satova koji odbrojavaju u stvarnom vremenu, operacijski sustav može imati i satove koji odbrojavaju u vremenima koja odgovaraju dodijeljemo vremenu procesu ili dretvi (u korisničkom i jezgrinom načinu rada). Ti se satovi uglavnom koriste za analizu rada programa, a ne za upravljanje.

6.1.2. Dohvat trenutnog vremena, odgoda dretve

Dohvat trenutnog vremena u većoj preciznosti može se obaviti funkcijom:

```
int clock_gettime(clockid_t clock_id, struct timespec *tp);
```

Parametar clock_id određuje sat koji će se koristiti u operaciji (npr. CLOCK_REALTIME). Pri interpretaciji vrijednosti koje funkcija vraća treba uzeti u obzir granulaciju sata.

Odgode izvođenja dretvi mogu se ostvariti sučeljem clock_nanosleep.

```
int clock_nanosleep(clockid_t clock_id, int flags, const struct timespec *rqtp,
                    struct timespec *rmtp);
```

Odgoda može biti zadana relativno u odnosu na trenutak poziva – trenutno vrijeme (npr. “za 20 ms”), ili apsolutno, do određenog vremena (npr. “do 12:35:21.527”). U drugom slučaju je potrebno postaviti zastavicu TIMER_ABSTIME u drugom parametru (flags).

Ako se dretva probudi prije isteka zadanog intervala, primjerice zbog signala, tada se u zadnjem parametru (ako nije NULL) vrati neprospavano vrijeme.

Isječak kôda 6.1. Primjer korištenja satnih mehanizama

```
#include <stdio.h>
#include <time.h>
#include <pthread.h>

#define BROJ_DRETVI 3
#define BROJAC 30000000ULL /* Prilagoditi brzini procesora */

static pthread_mutex_t monitor = PTHREAD_MUTEX_INITIALIZER;
static struct timespec t0, tx0;

void timespec_add(struct timespec *A, struct timespec *B);
void timespec_sub(struct timespec *A, struct timespec *B);
void timestamp(long id, char *msg, int iter);
static void *posao_dretve(void *param);

int main ()
{
    long i;
    pthread_t tid[BROJ_DRETVI];
```

```
    clock_gettime(CLOCK_REALTIME, &t0); /* vrijeme početka */
    clock_gettime(CLOCK_MONOTONIC, &tx0);

    for (i = 0; i < BROJ_DRETVI; i++) {
        if (pthread_create(&tid[i], NULL, posao_dretve, (void *) (i+1)))
        {
            perror("Error: pthread_create");
            return 1;
        }
    }

    for (i = 0; i < BROJ_DRETVI; i++)
        pthread_join(tid[i], NULL);

    return 0;
}

static void *posao_dretve(void *param)
{
    long id = (long) param;
    int iter;
    struct timespec iduca_aktivacija, period;
    unsigned long long i;

    /* period = 500 ms * id */
    period.tv_sec = id / 2;
    period.tv_nsec = (id % 2) * 500000000;

    iduca_aktivacija = tx0;

    for (iter = 0; iter < 100; iter++)
    {
        timestamp(id, "POCETAK", iter);
        for (i = 0; i < id * BROJAC; i++)
            asm volatile ("":::"memory");
        timestamp(id, "KRAJ", iter);

        timespec_add(&iduca_aktivacija, &period);
        clock_nanosleep(CLOCK_MONOTONIC, TIMER_ABSTIME,
                        &iduca_aktivacija, NULL);
    }

    return NULL;
}

void timespec_add(struct timespec *A, struct timespec *B)
{
    A->tv_sec += B->tv_sec;
    A->tv_nsec += B->tv_nsec;
    if (A->tv_nsec >= 1000000000) {
        A->tv_sec++;
        A->tv_nsec -= 1000000000;
    }
}

void timespec_sub(struct timespec *A, struct timespec *B)
{
    A->tv_sec -= B->tv_sec;
    A->tv_nsec -= B->tv_nsec;
    if (A->tv_nsec < 0) {
        A->tv_sec--;
```

```
        A->tv_nsec += 1000000000;
    }
}

void timestamp(long id, char *msg, int iter)
{
    struct timespec t;
    pthread_mutex_lock(&monitor);
    clock_gettime(CLOCK_REALTIME, &t);
    timespec_sub(&t, &t0);
    printf("[%02ld:%06ld] Dretva %ld: %s iteracija=%d\n",
        t.tv_sec % 100, t.tv_nsec/1000, id, msg, iter);
    pthread_mutex_unlock(&monitor);
}

/* Primjer pokretanja: (na jednoprocesorskom sustavu !!!)
$ gcc periodic-tasks-1.c -pthread -Wall
$ ./a.out
[00:000140] Dretva 3: POCETAK iteracija=0
[00:000460] Dretva 2: POCETAK iteracija=0
[00:008245] Dretva 1: POCETAK iteracija=0
[00:246640] Dretva 1: KRAJ iteracija=0
[00:418966] Dretva 2: KRAJ iteracija=0
[00:500457] Dretva 1: POCETAK iteracija=1
[00:522505] Dretva 3: KRAJ iteracija=0
[00:613793] Dretva 1: KRAJ iteracija=1
[01:000499] Dretva 2: POCETAK iteracija=1
[01:004525] Dretva 1: POCETAK iteracija=2
...
*/
```

Obzirom da se u primjeru koriste obične dretve, one dijele procesorsko vrijeme. Dretva 1 ima najmanje posla pa prva završava, ali se opet i prva javlja u budućnosti obzirom na najkraću periodu.

6.1.3. Periodički alarm

Periodički alarm, kako mu i ime kaže, koristi se za ostvarenje periodičkih operacija. Zadaje se s periodom i operacijom (funkcijom) koju treba periodički pozivati.

Sučelje za ostvarenje periodičkog alarma, uključujući pomoćne funkcije, je:

```
int timer_create(clockid_t clockid, struct sigevent *evp, timer_t *timerid);
int timer_settime(timer_t timerid, int flags, const struct itimerspec *value,
                  struct itimerspec *ovalue);
int timer_gettime(timer_t timerid, struct itimerspec *value);
int timer_getoverrun(timer_t timerid);
int clock_getres(clockid_t clock_id, struct timespec *res);
int sigaction(int sig, const struct sigaction *act, struct sigaction *oact);
```

Prva funkcija, `timer_create`, samo stvara jedan alarm, ali ga ne aktivira. Funkcijom se određuje po kojem će satu odbrojavati i što će se dogoditi po aktivaciji.

Preko strukture `sigevent` se definira akcija koju treba poduzeti pri aktiviranju alarma (kada zadano vrijeme istekne). Struktura se koristi i općenitije za definiranje akcije na neki događaj, ne samo za alarme već i za signale. Struktura `sigevent` se sastoji od sljedećih elemenata:

- `sigev_notify` – definira način akcije na događaj:
  - `SIGEV_NONE` – nema akcije

  - SIGEV_SIGNAL – akcija na događaj je slanje signala sigev_signo (najčešći odabir u nekritičnim sustavima)
  - SIGEV_THREAD – akcija na događaj je stvaranje nove dretve koja obrađuje događaj funkcijom sigev_notify_function uz parametar sigev_value
  - SIGEV_THREAD_ID – signal se ne šalje pozivajućoj dretvi (koja je postavila alarm) već dretvi definiranoj sa sigev_notify_thread_id (proširenje koje donosi *Linux*, nije definirano *POSIX*-om)
- sigev_signo – identifikacijski broj signala koji se šalje (kada se signal šalje kao aktivacija događaja)
- sigev_value – vrijednost (broj ili kazaljka) koja se šalje uz aktivaciju događaja uz signal ili kao parametar funkcije sigev_notify_function
- sigev_notify_function – početna funkcija nove dretve stvorene kao reakcija na aktiviranje događaja (uz sigev_notify==SIGEV_THREAD)
- sigev_notify_attributes – postavke za novu dretvu
- sigev_notify_thread_id – opisnik dretve kojoj treba poslati signal, kada je akcija na događaj aktivacije slanje signala.

Opisnik stvorenog alarma (u funkciji timer_create) sprema se na adresu zadanu varijablom timerid. Ista se adresa koristi u idućim funkcijama (nakon stvaranja alarma).

Funkcijom timer_settime alarm se aktivira. Struktura itimerspec definira vrijeme prvog pojavljivanja (aktiviranja) alarma (value->it_value) te naknadna periodička ponavljanja (value->it_interval). Svako aktiviranje alarma popraćeno je slanjem definiranog signala procesu ili druge radnje, prema postavljenom ponašanju s timer_create.

Vrijeme do iduće aktivacije alarma može se dohvatiti s timer_gettime.

Ako je aktivacija alarma ostvarena signalom, moguće je da zbog raznih razloga (npr. zbog prioritetnijih dretvi) prethodni signal još nije prihvaćen i obrađen do trenutka pojave novog signala (idući interval). S obzirom na to da se standardni signali ne gomilaju, operacijski sustav će po procesu zapamtiti samo jedan signal istog tipa koji čeka na obradu. Funkcijom timer_getoverrun može se provjeriti je li došlo do takvog prekoračenja u prihvatu i obradi signala, te ako je, koliko puta.

Iako sučelje dozvoljava definiranje vremena u granulama od nanosekunde, stvarna granulacija može biti znatno grublja. Informacije o granulaciji, tj. rezoluciji korištenog sata u danom sustavu mogu se dohvatiti funkcijom clock_getres.

Akciju na signal treba definirati odgovarajućim sučeljem, primjerice sa sigaction, koje ima najviše mogućnosti.

Isječak kôda 6.2. Primjer korištenja periodičkih alarma

```
#include <stdio.h>
#include <stdlib.h>
#include <time.h>
#include <signal.h>

/* makro koji pojednostavljuje poziv funkcija uz provjeru grešaka */
#define WARN    0
#define STOP    1
#define CALL(ACT,FUNC,...)        \
do {                              \
    if (FUNC(__VA_ARGS__)) {      \
```

```
        perror(#FUNC);            \
        if (ACT == STOP)          \
            exit(1);              \
    }                             \
} while(0)

static int act[2] = {0, 0};

static void dretva_za_alarm(union sigval val)
{
    printf("Alarm %d [%d]\n", val.sival_int, ++act[val.sival_int-1]);
}

int main()
{
    timer_t timer1, timer2;
    struct sigevent event;
    struct itimerspec period;
    struct timespec t;

    event.sigev_notify = SIGEV_THREAD;
    event.sigev_notify_function = dretva_za_alarm;
    event.sigev_notify_attributes = NULL;

    event.sigev_value.sival_int = 1;
    CALL(STOP, timer_create, CLOCK_REALTIME, &event, &timer1);
    //timer_create(CLOCK_REALTIME, &event, &timer1); uz provjere

    event.sigev_value.sival_int = 2;
    CALL(STOP, timer_create, CLOCK_REALTIME, &event, &timer2);

    period.it_value.tv_sec = period.it_interval.tv_sec = 1;
    period.it_value.tv_nsec = period.it_interval.tv_nsec = 0;
    CALL(STOP, timer_settime, timer1, 0, &period, NULL);

    period.it_value.tv_sec = period.it_interval.tv_sec = 2;
    CALL(STOP, timer_settime, timer2, 0, &period, NULL);

    t.tv_sec = 10;
    t.tv_nsec = 0;
    CALL(WARN, nanosleep, &t, NULL);

    return 0;
}
```

6.2. Nadzorni alarm

Sustavi za rad u stvarnom vremenu se projektiraju i ispituju znatno strože od ostalih sustava. Često su oni ugrađeni u druge sustave te su zato projektirani tako da mogu dugotrajno raditi bez vanjske intervencije. Ipak, sustavi bez i jedne greške su vrlo rijetki. Razlog tome jest složenost sustava i nemogućnost potpunog ispitivanja. Neočekivani ulazi i situacije, kao primjerice kratkotrajni strujno/naponski poremećaj također uzrokuju probleme.

Što napraviti kada sustav zataji, odnosno kako izgraditi sustav da se pokuša sam oporaviti nakon zatajenja? Postoji nekoliko mogućnosti.

Prva je da sustav stane i čeka intervenciju nadležnog nadzornika koji će ispitati uzroke zatajenja i ponovno pokrenuti sustav, ako to ima smisla. Pritom će uzrok zatajenja iskoristiti za ispravljanje greške u programu (ili isti dojaviti razvojnom timu). Jedan od mogućih nedostataka ovog

pristupa je u vremenu rekacije nadzornika, koje se može mjeriti i satima ili čak i danima.

Drugi pristup zasniva se na vjerojatnosti da se kvar koji dovodi sustav do zatajenja javlja vrlo rijetko, u sklopu poklapanja vrlo malo vjerojatnih događaja koji nisu predviđeni pri izgradnji sustava. Moguće je da se slična situacija neće još dugo ponoviti. Zato je jedan od uobičajenih postupaka pri zatajenjima u računalnom sustavu, sustav ponovno dovesti u početno stanje i pokrenuti (engleski termin *reset* se u našem jeziku udomaćio kao "resetirati"). Naravno, neće sva zatajenja biti moguće riješiti na taj način, ali mnoga hoće. Postavlja se pitanje kako ustanoviti da je sustav zatajio i kako ga zaustaviti, dovesti u početno stanje i ponovno pokrenuti? Jedan od načina je korištenjem nadzornog alarma koji je spojen na ulaz (pin) RESET procesora.

Nadzorni alarm (engl. *watchdog timer*) je brojilo koje odbrojava od zadane vrijednosti do nule, u taktu signala koji je na njega spojen. Ispravan upravljački program (dretva) će periodički poništavati nadzorni alarm – učitati proračunatu vrijednost u brojilo. Takvim poništavanjem dretva signalizira ispravni rad. Ako se nešto neočekivano dogodi (dretva se blokira, zavrti u beskonačnoj petlji ili neka druga programska greška u ovoj ili nekoj drugoj dretvi ili operacijskom sustavu), tj. ako sustav zataji, brojilo nadzornog alarma odbrojat će do kraja – do nule. Kada se to dogodi, nadzorni alarm će postaviti električni signal koji je spojen s ulazom RESET procesora te će se sustav ponovno pokrenuti (resetirati).

Ostvarenje nadzornog alarma zahtjeva analizu i odabir periode u kojima nadzorni alarm treba signalizirati (poništiti) od strane programa koji se nadzire. Također, signalizaciju treba ugraditi u sam program, tj. treba odabrati dijelove kôda u koji treba ugraditi pozive za signalizaciju nadzornog alarma. Nadzorni alarm se ostvaruje kao zasebni sklop u računalu ili pak kao dio procesora.

Primjer 6.1. Primjer korištenja nadzornog alarma

```
int main()
{
    uint16 volatile *brojilo = (uint16 volatile *) 0xFF0000;

    inicijalizacija();

    for (;;) {
        *brojilo = 10000;
        očitaj_stanje_senzora();
        izračunaj_i_pošalji_naredbe();
        zapiši_stanje_sustava();
    }
}
```

Izvedbe nadzornog alarma mogu biti i složenije, npr. prema [Murphy, 2000]. Ponekad je bitno otkriti i prerana poništavanja ako je poznat minimalni interval koji treba proteći.

Nadzorni alarm bi se za manje zahtjevne sustave mogao i programski ostvariti korištenjem satnih mehanizama operacijskog sustava. Međutim, takvi nadzorni alarmi imaju značajna ograničenja u korištenju. Signali, koji se koriste za njihovu aktivaciju mogu biti programski isključeni za dotični proces te nikakve reakcije na alarm neće biti u takvom slučaju.

Pitanja za vježbu 6

1. Opisati uzroke grešaka u korištenju vremena preko sučelja operacijskih sustava.
2. Navesti operacije povezane s upravljanjem vremenom koje nude operacijski sustavi.
3. Koja je razlika između satova označenih sa `CLOCK_REALTIME` i `CLOCK_MONOTONIC`?
4. Opisati svrhu te korištenje nadzornog alarma.

7. Višedretvena sinkronizacija i komunikacija

Potreba za sinkronizacijom proističe iz toga što ima više dretvi koje istovremeno traže korištenje ograničenog broja sredstava sustava (objekata, naprava i slično). Korištenje sredstava treba ograničiti tako da manji broj dretvi istovremeno koriste sredstva, a najčešće da samo jedna dretva istovremeno koristiti jedno sredstvo.

Uobičajeni mehanizmi sinkronizacije dretvi uključuju međusobno isključivanje nad kritičnim odsječkom, semafore, monitore, zaključavanja čitaj/piši, zaključavanja radnim čekanjem (engl. *spinlock*) i barijeru.

Međusobno isključivanje se najčešće ostvaruje sa semaforima i monitorima. U sustavima u kojima programi mogu dobiti vrlo veliku kontrolu nad sustavom, međusobno isključivanje se može ostvariti i onemogućavanjem i naknadnim omogućavanjem prekida (na razini procesora).

U ovom poglavlju ukratko su prikazane neke od mogućnosti sinkronizacije i komunikacije, ostvarive kroz POSIX sučelje današnjih operacijskih sustava.

7.1. Sinkronizacija semaforima

Semafor je vrlo jednostavan sinkronizacijski mehanizam jezgre operacijskog sustava uz koji su pridjeljeni podaci: vrijednost semafora i red za blokirane dretve na tom semaforu. Semafor je "prolazan" ako mu je vrijednost veća od nule, a neprolazan ako mu je vrijednost jednaka nuli. Semafor može zbog toga brojati koliko u nekom trenutku ima nečega na raspolaganju. Dok ima tih sredstava, dretve koje pozivaju *ČekajSemafor* će proći taj semafor i pritom smanjiti njegovu vrijednost za jedan te (nakon poziva *ČekajSemafor*) uzeti (koristiti) tražena sredstva. Kada vrijednost tog semafora postane nula, sve iduće dretve će se istim pozivom blokirati na tom semaforu. Pozivom *PostaviSemafor* vraća se sredstvo te se odblokira prva blokirana dretva na tom semaforu, ili ako nema takvih dretvi, vrijednost semafora se povećava za jedan. Primjer sinkronizacije semaforima prikazan je u nastavku.

Primjer 7.1. Sinkronizacija jednog proizvođača s jednim potrošačem

```
dretva proizvođač
    ponavljaj
        p = proizvedi_poruku()
        ČekajSemafor(prazna)
        međuspremnik[ulaz] = p
        ulaz = (ulaz+1) mod N
        PostaviSemafor(puna)
```

```
dretva potrošač
    ponavljaj
        ČekajSemafor(puna)
        r = međuspremnik[izlaz]
        izlaz = (izlaz+1) mod N
        PostaviSemafor(prazna)
        potroši_poruku(r)
```

Početna vrijednost semafora `prazna` mora biti postavljena na `N` (veličina međuspremnika), a početna vrijednost semafora `puna` na 0. Pomoćne varijable `ulaz` i `izlaz` početno trebaju imati vrijednost 0.

Osnovno sučelje za rad sa semaforima (prema POSIX-u) sastoji se od:

```
int sem_init(sem_t *sem, int pshared, unsigned init_value);
int sem_post(sem_t *sem);
int sem_wait(sem_t *sem);
int sem_trywait(sem_t *sem);
int sem_timedwait(sem_t *sem, const struct timespec *max_wait);
```

Sučelje `sem_trywait` je neblokirajuća inačica poziva za čekanje, koja će u slučaju da se semaforu vrijednost ne može smanjiti za jedan vratiti grešku kao povratnu vrijednost te pritom neće blokirati dretvu.

Ograničeno blokiranje pruža sučelje `sem_timedwait` koje će nakon isteka zadanog vremena dretvu odblokirati, ako se u međuvremenu nije odblokirala uobičajenim načinom, pozivom `sem_post` od strane neke druge dretve.

Drugo sučelje za rad s ponešto drukčijim semaforima drukčijih mogućnosti uključuje: `semget`, `semop` te `semctl`.

Semafori su gotovo najjednostavniji sinkronizacijski mehanizam te su pogodni za jednostavnije potrebe. Međutim, zbog toga su neprikladni za sinkronizacije kojima se štiti više od jednog sredstva. Korištenje u takvim situacijama može dovesti do problema potpunog zastoja.

7.2. Potpuni zastoj

Potpuni zastoj (engl. *deadlock*) je stanje sustava dretvi u kojemu su sve dretve blokirane te ne postoji mogućnost njihova nastavka rada. Potpuni zastoj može nastati u sustavu s više dretvi od kojih svaka u nekom trenutku svog izvođenja traži više od jednog sredstva, a svako je sredstvo zaštićeno zasebnim sinkronizacijskim objektom.

Najjednostavniji primjer uključuje dvije dretve i dva sredstva. U takvom sustavu može se dogoditi da svaka dretva zauzme po jedno sredstvo te se blokira na zahtjevu za drugim (koje ima druga dretva). Najčešći primjer koji se spominje u ovom kontekstu jest problem pet filozofa smišljen od strane Edsgera Dijkstre 1965. te kasnije korišten u gotovo svakoj literaturi te tematike (npr. [Budin, 2011]).

Primjer 7.2. Sinkronizacija više proizvođača i više potrošača, s greškom

Neka se u pokušaju proširenja rješenja iz primjera 7.1. na više proizvođača i više potrošača, doda dodatni semafor `ko`, s početnom vrijednošću 1 koji će spriječiti više istovremenih pristupa međuspremniku.

```
dretva proizvođač
    ponavljaj
        p = proizvedi_poruku()
        ČekajSemafor(prazna)
        ČekajSemafor(ko)
        međuspremnik[ulaz] = p
        ulaz = (ulaz+1) mod N
        PostaviSemafor(ko)
        PostaviSemafor(puna)
```

```
dretva potrošač
    ponavljaj
        ČekajSemafor(ko)
        ČekajSemafor(puna)
        r = međuspremnik[izlaz]
        izlaz = (izlaz+1) mod N
        PostaviSemafor(prazna)
        PostaviSemafor(ko)
        potroši_poruku(r)
```

Zbog različitog dodavanja tog semafora kod proizvođača i potrošača (ovdje namjernom ilustrativnom greškom), može se dogoditi da jedan potrošač prođe semafor `ko` (i pritom ga postavlja u neprolazno stanje) te se i sam blokira na semaforu `puna` (u početku je međuspremnik prazan). Nakon toga niti jedan proizvođač neće moći ući u svoj kritični odsječak i staviti poruku u međuspremnik (i pozvati `PostaviSemafor`) te će se sve dretve blokirati – nastaje potpuni zastoj.

U prethodnom primjeru se potpuni zastoj može izbjeći opreznim programiranjem. Međutim, općenito se problem potpunog zastoja ne može riješiti na taj način. Zato je preporuka da se u slučaju potrebe složenijeg sinkronizacijskog mehanizma ne koriste semafori već monitori.

7.3. Sinkronizacija monitorima

Sinkronizacijski mehanizam monitora omogućava da se problemi dostupnosti sredstava izražavaju proizvoljno i programski ispituju izvan jezgre, a ne kao kod semafora u jezgri operacijskog sustava korištenjem vrijednosti semafora. Zato se pri korištenju monitora treba definirati i dodatna struktura podataka koja će pratiti stanje sustava (raspoloživost sredstava).

Monitor se ostvaruje sučeljem jezgre operacijskog sustava:

- ulazak u monitor (`Uđi_u_monitor`),
- izlazak iz monitora (`Izađi_iz_monitora`)
- blokiranje unutar monitora (`Čekaj_u_red_uvjeta`)
- propuštanje blokiranih dretvi (`Oslobodi_iz_reda_uvjeta`).

Pokažimo primjenu tih funkcija na rješavanje istog problema sinkronizacije i komunikacije dretvi proizvođača i potrošača.

Primjer 7.3. Sinkronizacija proizvođača i potrošača s monitorom

```
dretva proizvođač
  ponavljaj
    p = proizvedi_poruku()
    Uđi_u_monitor(m)
    dok je (br_poruka == N)
      Uvrsti_u_red_uvjeta(prazna, m)
    međuspremnik[ulaz] = p
    ulaz = (ulaz + 1) mod N
    br_poruka = br_poruka + 1
    Oslobodi_iz_reda_uvjeta(puna, m)
    Izađi_iz_monitora(m)
```

```
dretva potrošač
  ponavljaj
    Uđi_u_monitor(m)
    dok je (br_poruka == 0)
      Uvrsti_u_red_uvjeta(puna, m)
    r = međuspremnik[izlaz]
    izlaz = (izlaz + 1) mod N
    br_poruka = br_poruka - 1
    Oslobodi_iz_reda_uvjeta(prazna, m)
    Izađi_iz_monitora(m)
    potroši_poruku(r)
```

Umjesto brojača broja slobodnih i punih mjesta u međuspremniku koji su u primjeru sa semaforima bili dio semafora, sada je potrebno dodatnim varijablom `br_poruka` pratiti koliko se poruka nalazi u međuspremniku. Ta se varijabla ispituje nakon ulaska u monitor, a prije korištenja međuspremnika (za stavljanje nove poruke ako ima mjesta, te za uzimanje poruke, ako međuspremnik nije prazan).

Uvjet koji se ispituje unutar monitora, a koji će služiti za odluku da li dretvu pustiti dalje ili ju blokirati, može biti vrlo složen (u prethodnom primjeru je to samo ispitivanje jedne varijable). Zbog toga se i u složenim sinkronizacijskim problemima monitori na isti način koriste – samo je uvjet ispitivanja drugi. Potpuni zastoj je stoga mnogo jednostavnije izbjeći.

Osim već osnovnih funkcija za ostvarenje monitora, kao i kod sučelja za semafore i kod monitora imamo dodatne mogućnosti u obliku neblokirajućih „čekaj“ funkcija i vremenski ograničenih blokiranja. Popis najbitnijih sučelja je:

```
int pthread_mutex_init(pthread_mutex_t *mutex, const pthread_mutexattr_t *attr);
int pthread_mutex_lock(pthread_mutex_t *mutex);
int pthread_mutex_unlock(pthread_mutex_t *mutex);
int pthread_cond_init(pthread_cond_t *cond, const pthread_condattr_t *attr);
int pthread_cond_wait(pthread_cond_t *cond, pthread_mutex_t *mutex);
int pthread_cond_signal(pthread_cond_t *cond);
int pthread_cond_broadcast(pthread_cond_t *cond);
int pthread_mutex_trylock(pthread_mutex_t *mutex);
int pthread_mutex_timedlock(pthread_mutex_t *mutex, const struct timespec *abstm);
int pthread_cond_timedwait(pthread_cond_t *cond, pthread_mutex_t *mutex,
                           const struct timespec *abstm);
```

7.4. Rekurzivno zaključavanje

Što napraviti ako dretva koja je već zaključala semafor ili monitor opet pokuša zaključati isti objekt (semafor ili monitor)? To se može smatrati greškom u programu ili se želi takvo ponašanje podržano implementacijom. Npr. neka se iz početne funkcije koje je ušla u monitor pozivaju druge funkcije koje i same imaju zaštitu od paralelnog pozivanja korištenjem istog monitora (zato što se pozivaju i izvan prve funkcije, tj. izvan monitora), kao u primjeru:

```
funkcija_1()
    Uđi_u_monitor(m)
    nešto_radi
    funkcija_2()
    još_radi
    Izađi_iz_monitora(m)
```

```
funkcija_2()
    Uđi_u_monitor(m)
    nešto_drugo_radi
    Izađi_iz_monitora(m)
```

Izlaziti iz monitora da bi se u njega opet ušlo, osim nepraktičnosti, može biti i loše rješenje, logički neispravno. Problem se može riješiti na nekoliko načina. Jedan od njih je i korištenje podrške za rekurzivno zaključavanje koje nude neki sinkronizacijski mehanizmi.

Takva podrška je predviđena POSIX standardom za mehanizam monitora, odnosno za pozive `pthread_mutex_lock`/`pthread_mutex_unlock`. Prilikom stvaranja takvog monitora potrebno je pozivom `pthread_mutexattr_settype` postaviti tip (`type`) `PTHREAD_MUTEX_RECURSIVE` atributu kojim se inicijalizira objekt zaključavanja.

Drugi način rješavanja prethodnog problema zahtjeva promjenu u izvornim kôdovima tako da se operacije u pseudokôdu označene s `nešto_drugo_radi` ostvare u zasebnoj funkciji koja nije zaštićena monitorom te da se poziva iz obje funkcije, tj. iz `funkcija_1` i `funkcija_2` (unutar monitora).

7.5. Problem inverzije prioriteta

Dretve u ugrađenim sustavima se međusobno razlikuju po važnosti, odnosno prioritetu. Pri dodjeli procesora dretva većeg prioriteta ima prednost ispred one manjeg prioriteta. Iako je takav ili slični slučaj i u ostalim sustavima, odnosno ostalim operacijskim sustavima koji nisu namijenjenih SRSV-ima, kod njih je prioritet uglavnom nešto što određuje koliko će pojedina dretva dobiti procesorskog vremena, a ne kada će ta dretva postati aktivna. U operacijskim sustavima za rad u stvarnom vremenu i za ugrađene sustave jasno je definirano da kada dretva višeg prioriteta postaje spremna za izvođenje ona istiskuje dretvu nižeg prioriteta koja se trenutno izvodi (kao što je već i prikazano u prethodnim poglavljima). Međutim, i u takvim se sustavima događaju slučajevi kada dretva nižeg prioriteta zaustavi izvođenje dretve višeg prioriteta, odnosno dolazi do problem *inverzije prioriteta*.

Problem inverzije prioriteta nastaje kada dretva višeg prioriteta za nastavak rada treba sredstvo koje je zauzela druga dretva nižeg prioriteta. Slika 7.1. prikazuje tri slučaja koja se mogu pojaviti u višedretvenom sustavu.

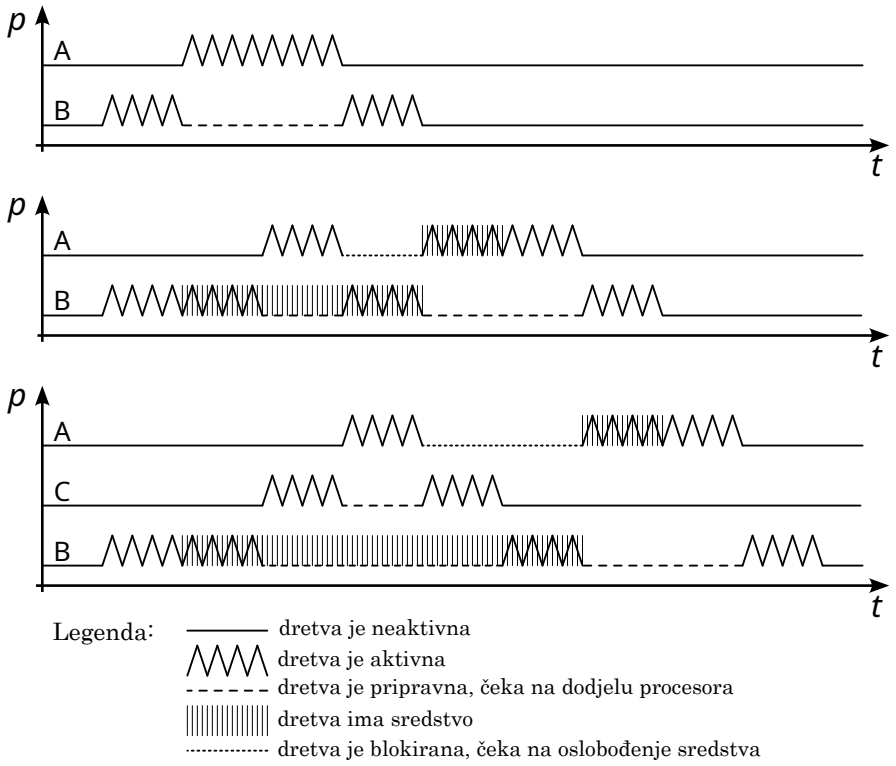

Slika 7.1. Problem inverzije prioriteta

Slika 7.1.(i) prikazuje uobičajeno ponašanje kada su u sustavu dvije dretve različitog prioriteta. Aktiviranjem prioritetnije dretve, manje prioritetna se istisne, tj. makne s procesora. Na slici, čim dretva A postane spremna istisne dretvu B, koja ima manji prioritet.

Slika 7.1.(ii) pokazuje sličnu situaciju, ali dretve A i B tijekom rada koriste zajedničko sredstvo i to međusobno isključivo (npr. zaštićeno binarnim semaforom). Dok je dretva A bila neaktivna dretva manjeg prioriteta – dretva B je bila aktivna te je za vrijeme svog rada zauzela sredstvo. Kasnije se dretva A aktivirala te odmah istisnula dretvu B. Međutim, u jednom trenutku dretvi A za nastavak rada treba sredstvo koje dretva B još nije otpustila (binarni semafor je neprolazan). Dretva A se zaustavi te dretva B, kao jedina dretva u sustavu nastavlja s radom. Problem koji je nastao naziva se problem inverzije prioriteta jer dretva manjeg prioriteta radi, dok dretva većeg prioriteta čeka na nju. Međutim, čim dretva B oslobodi zauzeto sredstvo, dretva A se otpusti i odmah zauzima sredstvo i nastavlja s radom (primjerice kad dretva B pozove *PostaviSemafor*).

Slika 7.1.(iii) prikazuje situaciju kad u sustavu osim dretvi A i B postoji i treća dretva C prioriteta većeg od dretve B, ali manjeg od dretve A. Kao što se vidi iz grafa, ovakva dretva može dodatno odgoditi izvođenje dretve A jer po blokiranju dretve A, s radom će nastaviti dretva C, a ne dretva B (koja blokira dretvu A). U sustavima s više dretvi vrlo je teško procijeniti koliko se dretva A može odgoditi. Zato je problem inverzije prioriteta vrlo opasan za sustave za rad u stvarnom vremenu.

Metode koje se najčešće koriste u slučajevima problema inverzije prioriteta ne rješavaju sam problem nego ublažavaju njegove posljedice. To rade tako da se dretvi koja je zauzela sredstva potrebna prioritetnijoj dretvi (korištenjem sinkronizacijskog mehanizma) omogući što brži rad do oslobađanja dotičnih sredstava. Dvije najpoznatije takve metode su:

- *protokol nasljeđivanja prioriteta* (engl. *priority inheritance protocol*) i
- *protokol stropnog prioriteta* (engl. *priority ceiling protocol*).

Važna pretpostavka za oba protokola je da dretve nakon što sredstvo zauzmu isto će i osloboditi nakon nekog vremena.

7.5.1. Protokol nasljeđivanja prioriteta

Protokol nasljeđivanja prioriteta privremeno podiže prioritet dretvi manjeg prioriteta kada ona blokira dretvu većeg prioriteta – dretva manjeg prioriteta naslijeđuje prioritet blokirane dretve. Nasljeđivanje prioriteta se događa u trenutku blokiranja dretve većeg prioriteta (npr. kada ona pozove *ČekajSemafor*).

Pri otpuštanju sredstva, dretvi se prioritet vraća na prijašnju vrijednost te konačno dretva višeg prioriteta zauzima sredstvo i nastavlja s radom. Povećanje prioriteta može biti i tranzitivno: najprije se poveća prioritet dretve koja drži sredstvo, a potom i prioritet dretvi koja blokira prethodnu radi drugog sredstva, itd. Kao i prethodnu funkciju i ovu mora slijediti poziv raspoređivača koji će uzeti u obzir nove prioritete.

Primjer rada protokola nasljeđivanja prioriteta prikazan je na slici 7.2.

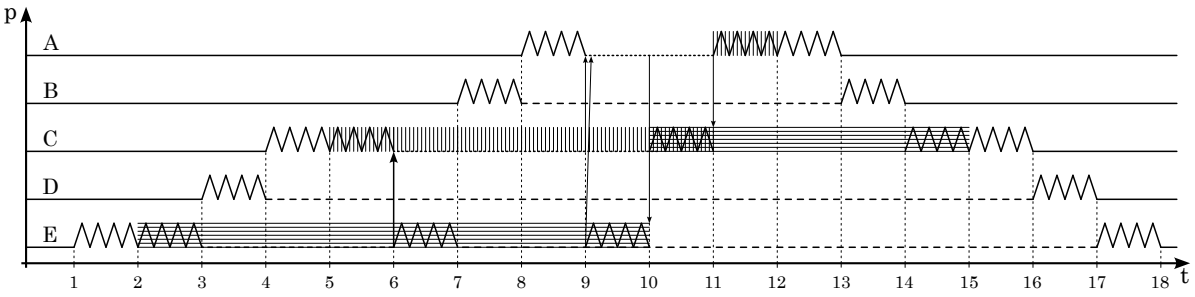

Opis grafa prema trenucima:

1. E kao jedina pripravna dretva započinje s radom
2. E zauzima sredstvo S_1 (vodoravne crte)
3. D započinje s radom i istiskuje E jer ima veći prioritet
4. C započinje s radom i istiskuje D jer ima veći prioritet
5. C zauzima sredstvo S_2 (okomite crtice)
6. C treba S_1 koji je E zauzela, E nasljeđuje prioritet od C te E nastavlja s radom (s prioritetom od C)
7. B započinje s radom i istiskuje E jer ima veći prioritet
8. A započinje s radom i istiskuje B jer ima veći prioritet
9. A treba S_2 koji je C zauzela, C nasljeđuje prioritet od A, E nasljeđuje prioritet od C i E nastavlja s radom (s prioritetom od A)
10. E oslobađa S_1, vraća joj se početni prioritet, C zauzima S_1 i nastavlja s radom (s prioritetom od A)
11. C oslobađa S_2, vraća joj se početni prioritet, A zauzima S_2 i nastavlja s radom
12. A oslobađa S_2 i nastavlja s radom
13. A završava, B nastavlja s radom (ima najveći prioritet)
14. B završava, C nastavlja s radom (ima najveći prioritet)
15. C oslobađa S_1 i nastavlja s radom
16. C završava, D nastavlja s radom (ima najveći prioritet)
17. D završava, E nastavlja s radom (jedina dretva)
18. E završava

Slika 7.2. Primjer korištenja protokola nasljeđivanja prioriteta

Uz protokol nasljeđivanja prioriteta veže se zanimljivost iz svemirske misije na Mars robotske letjelice *Mars Pathfinder* [Jones, 1997] koja je bila upravljana operacijskim sustavom [VxWorks]. Nakon uspješnog slijetanja i prvih nekoliko dana rada, na sustavu upravljanja počeli su se pojavljivati neobjašnjivi i učestali prekidi. Kako je sustav napravljen da prilikom detekcije greške prekida rad i ponovo pokreće cijeli sustav (mehanizmom nadzornog alarma) sve je do određene mjere i dalje radilo. Greška koja je za nekoliko dana pronađena te potom i uklonjena jest u protokolu nasljeđivanja prioriteta, koji je bio greškom isključen. Problem je nastao kada je

prioritetnoj dretvi na dulje vrijeme bio uskraćen pristup sabirnici što je sklop za nadzor interpretirao kao kritičnu grešku te je zaustavio i ponovo pokrenuo sustav. Uključivanje protokola nasljeđivanja prioriteta riješilo je problem.

Protokol nasljeđivanja prioriteta ne rješava problem potpunog zastoja već se za sprječavanje i rješavanje istog moraju upotrijebiti dodatni algoritmi ili postupci.

7.5.2. Protokol stropnog prioriteta

Za protokol stropnog prioriteta postoje dvije inačice:

- pojednostavljeni protokol stropnog prioriteta i
- izvorni protokol stropnog prioriteta.

7.5.2.1. Pojednostavljeni protokol stropnog prioriteta

Pojednostavljeni protokol ima još nekoliko naziva: izravni protokol stropnog prioriteta (engl. *immediate ceiling priority protocol*), protokol zaštite prioritetom (engl. *priority protect protocol*) kod POSIX standarda te oponašanje protokola stropnog prioriteta (engl. *priority ceiling emulation*) kod programskog jezika Java.

Kod pojednostavljenog protokola stropnog prioriteta dretvi se odmah pri zauzimanju sredstva podigne prioritet na unaprijed izračunatu stropnu vrijednost. Na taj se način za vrijeme korištenja nekog sredstva dretvama povećava prioritet da bi one što prije završile s njegovim korištenjem i oslobodile ga za dretve višeg prioriteta. Protokol je jednostavniji za ostvarenje od prethodnog, ali je možda nepravedan. Dretva nižeg prioriteta zauzećem određenog sredstva dobiva veći prioritet i istiskuje (idući rad) prioritetnije dretve čak i onda kada od dretvi višeg prioriteta ne postoji potreba za sredstvom. S druge strane, obzirom da bi za većinu sustava kôd trebao biti oblikovan tako da dio nakon zauzeća sredstva do njegova otpuštanja traje vrlo kratko, ovo možda i nije loše rješenje za takve sustave.

7.5.2.2. Izvorni protokol stropnog prioriteta

Izvorni protokol ima za cilj i izbjegavanje nastajanja potpunog zastoja. Načelna ideja protokola jest da kada dretva želi zauzeti neki semafor tada ona mora imati veći prioritet od najveća stropna prioriteta nekog od već zauzetih semafora. Ako nema takav prioritet, onda joj se ne dopušta da zauzme semafor iako je on možda i u prolaznom stanju. Definicija protokola koja slijedi zasniva se na opisu iz [Rajkumar, 1991].

Osnovne pretpostavke:

1. Razmatra se skup dretvi $\{\mathcal{D}_1, \mathcal{D}_2, \ldots \mathcal{D}_N\}$ koje u dijelovima svog izvođenja koriste razna sredstva zaštićena binarnim semaforima $\{\mathcal{S}_1, \mathcal{S}_2, \ldots \mathcal{S}_M\}$. Za svaku je dretvu unaprijed poznato koje semafore će možda trebati tijekom rada, odnosno za svaki je semafor poznato koje ga dretve mogu koristiti. Za svaki se semafor izračunava stropni prioritet $p(S_i)$ tako da se odabere najveća vrijednost među prioritetima dretvi koje koriste taj semafor.
2. Koristi se prioritetno raspoređivanje – pripravna dretva najvećeg prioriteta se izvodi.

Rad protokola:

1. Dretva $\mathcal{D}_i$ poziva *ČekajSemafor(*S_x*)*:
   a) Niti jedan semafor nije zauzet – svi su prolazni.
      - Dretva $\mathcal{D}_i$ zauzima semafor S_x i nastavlja s radom (poziv radi uobičajeno).

b) Semafor S_x je već zauzet od dretve $\mathcal{D}_j$:

- Poziv blokira dretvu $\mathcal{D}_i$ te dretva $\mathcal{D}_j$ nasljeđuje prioritet od $\mathcal{D}_i$: $p(\mathcal{D}_j) = \max\{p(\mathcal{D}_j), p(\mathcal{D}_i)\}$.
- Nasljeđivanje prioriteta je tranzitivno: ukoliko je dretva $\mathcal{D}_j$ blokirana zbog semafora S_y i dretve $\mathcal{D}_k$, onda i dretva $\mathcal{D}_k$ nasljeđuje prioritet od $\mathcal{D}_i$. I tako dalje.

c) Semafor S_x nije zauzet, ali neki drugi semafori jesu:

- Neka S^* označava semafor najvećeg stropnog prioriteta $p(S^*)$ koji je zaključan od strane dretve $\mathcal{D}_k$.
- Ako je $\mathcal{D}_k = \mathcal{D}_i$ ili $p(\mathcal{D}_i) > p(S^*)$ tada dretva $\mathcal{D}_i$ zauzima semafor S_x i nastavlja s radom.
- Inače, ako je $p(\mathcal{D}_i) \leq p(S^*)$ poziv će blokirati dretvu $\mathcal{D}_i$ te dretva $\mathcal{D}_k$ nasljeđuje prioritet od $\mathcal{D}_i$: $p(\mathcal{D}_k) = \max\{p(\mathcal{D}_k), p(\mathcal{D}_i)\}$.
- Nasljeđivanje prioriteta je tranzitivno.

2. Dretva $\mathcal{D}_i$ poziva *PostaviSemafor(S_x)*.

a) Ako je dretvi $\mathcal{D}_i$ bio povećan prioritet radi korištenja semafora S_x, prioritet joj se vraća na prijašnju vrijednost.

b) Semafor S_x se postavlja u prolazno stanje.

c) Ako ima blokiranih dretvi zbog toga što je dretva $\mathcal{D}_i$ imala semafor S_x onda se najprioritetnija od njih odblokira te ona ponovno izvodi svoj poziv *ČekajSemafor(S_y)* prema ovom protokolu.

Analizom ovog protokola može se ustanoviti sličnost s protokolom nasljeđivanja prioriteta. I kod ovog se protokola prioritet zaustavljene dretve nasljeđuje u trenutku zaustavljanja. Osnovna je razlika što se u nekim slučajevima dretvi neće dozvoliti zaključavanje semafora iako je on slobodan, a zbog mogućeg zaustavljanja dretvi većeg prioriteta nad drugim semaforima. Na prvi pogled to zaustavljanje izgleda nepotrebno, ali ono zapravo pridonosi rješavanju problema potpunog zastoja, barem osnovnih oblika potpunog zastoja. U slučajevima gdje je problem potpunog zastoja značajan i često se pojavljuje, ovaj protokol može biti dobar odabir (iako bi u takvom sustavu bilo bolje koristiti monitore).

Primjer 7.4. Izbjegavanje potpunog zastoja

Slika 7.3. prikazuje primjer pojavljivanja potpunog zastoja (i) kao i njegovog izbjegavanja korištenjem protokola stropnog prioriteta (ii).

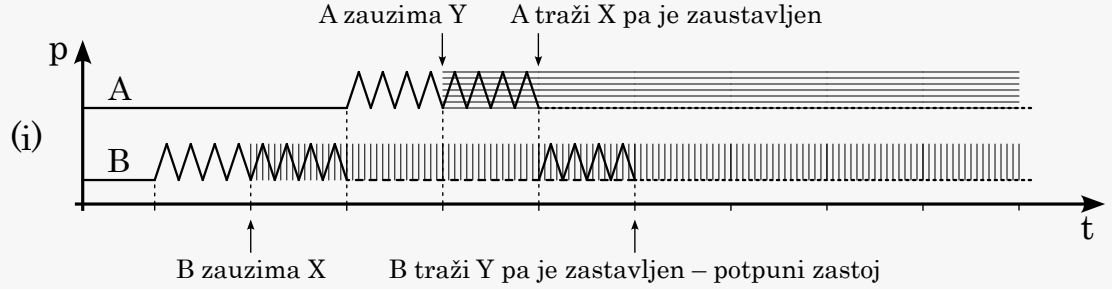

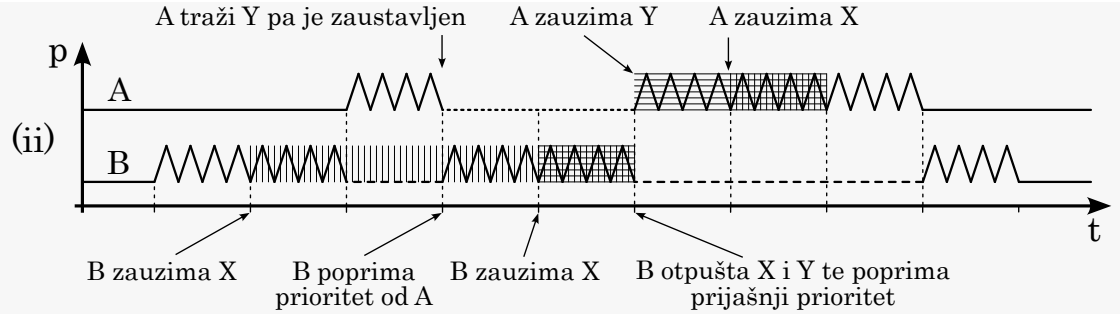

Slika 7.3. Primjer potpunog zastoja i kako ga stropni protokol izbjegava

Primjer 7.5. Rad izvornog protokola stropnog prioriteta

Pretpostavimo da u nekom sustavu imamo 4 dretve, svaku zadanu s prioritetima i sredstvima koje koristi u dijelovima svog izvođenja prema tablici 7.1. Analizom tih podataka mogu se odrediti stropni prioriteti za sredstva prema tablici 7.2.

Tablica 7.1. Sustav zadataka

Dretva	Prioritet	Sredstva
$\mathcal{D}_1$	20	S_1, S_2
$\mathcal{D}_2$	15	S_2, S_3
$\mathcal{D}_3$	10	S_3, S_4
$\mathcal{D}_4$	5	S_1, S_3

Tablica 7.2. Stropni prioriteti

Sredstvo	Stropni prioritet
S_1	20
S_2	20
S_3	15
S_4	10

Jedan mogući scenarij aktivacije pojedinih dretvi te njihove radnje prikazan je u nastavku. Neka su sredstva semafori i neka su svi početno postavljeni u vrijednost 1.

1. $\mathcal{D}_4$ se pojavljuje te kao dretva najvećeg prioriteta (jedina) odmah kreće s izvođenjem.
2. $\mathcal{D}_4$ poziva *ČekajSemafor(S_3)*.

   S obzirom na to da niti jedan semafor nije još zaključan (ne postoji S^*), a i S_3 je prolazan, poziv neće blokirati te će dretva $\mathcal{D}_4$ nastaviti s radom.

3. $\mathcal{D}_2$ se pojavljuje te kao dretva najvećeg prioriteta istiskuje $\mathcal{D}_4$ te se izvodi.
4. $\mathcal{D}_2$ poziva *ČekajSemafor(S_2)*.

   S^* (zaključani semafor najvećeg prioriteta) je S_3 sa stropnim prioritetom 15.

   $\mathcal{D}_2$ nema veći prioritet od 15 (ima 15), pa se blokira.

   $\mathcal{D}_4$ zbog toga (blokiranje $\mathcal{D}_2$) poprima prioritet od $\mathcal{D}_2$ (15) i nastavlja s radom.

5. $\mathcal{D}_1$ se pojavljuje te kao dretva najvećeg prioriteta istiskuje $\mathcal{D}_4$ te se izvodi.
6. $\mathcal{D}_1$ poziva *ČekajSemafor(S_1)*.

   S^* (zaključani semafor najvećeg prioriteta) je S_3 sa stropnim prioritetom 15.

$\mathcal{D}_1$ ima veći prioritet od 15 (ima 20), pa prolazi – zaključava S_1 i nastavlja s radom.

S^* je sada S_1.

7. $\mathcal{D}_1$ se blokira na nekom drugom redu (npr. čeka dovršetak neke ulazne operacije).

   $\mathcal{D}_4$ nastavlja s radom.

8. $\mathcal{D}_4$ otpušta sredstvo, tj. poziva *PostaviSemafor(S_3)*.

   Semafor S_3 se otključava.

   $\mathcal{D}_4$ poprima prijašnji prioritet, tj. 5.

   Provjerava se mogućnost propuštanja blokiranih dretvi, tj. dretve $\mathcal{D}_2$.

   S obzirom na to da je stropni prioritet od $S^* = S_1$ i dalje veći od prioriteta $\mathcal{D}_2$, $\mathcal{D}_2$ ostaje blokirana.

   $\mathcal{D}_4$ nastavlja s radom.

Izvorni protokol stropnog prioriteta pretpostavlja mogućnost da će dretva $\mathcal{D}_1$ trebati i S_2 te ne dozvoljava $\mathcal{D}_2$ da ga zauzme, s obzirom na to da je $\mathcal{D}_1$ već zauzeo S_1. Međutim, također treba primijetiti da dretva koja je zauzela semafor ne bi trebala odgađati svoj rad prije nego li otpusti semafor (što je $\mathcal{D}_1$ u ovom primjeru napravila), tako da bi se vrlo rijetko trebala pojavljivati situacija u kojoj $\mathcal{D}_2$ čeka na dretvu koja se neće izvoditi odmah nakon blokiranja $\mathcal{D}_2$.

7.5.3. POSIX funkcije za rješavanje problema inverzije prioriteta

POSIX definira mogućnost korištenja protokola nasljeđivanja prioriteta te pojednostavljenog protokola stropnog prioriteta na mehanizmu monitora, tako da se prije inicijalizacije monitora postave odgovarajuće zastavice attributa `attr` kojim se on inicijalizira.

Sučelje za postavljanje protokola za problem inverzije prioriteta je:

```
int pthread_mutexattr_setprotocol(pthread_mutexattr_t *attr, int protocol);
```

Protokol se odabire drugim parametrom. Mogućnosti su:

- `PTHREAD_PRIO_NONE` – bez korištenje ijednog protokola
- `PTHREAD_PRIO_INHERIT` – korištenje nasljeđivanja prioriteta
- `PTHREAD_PRIO_PROTECT` – korištenje stropnog prioriteta.

Kada se koristi zadnja opcija, `PTHREAD_PRIO_PROTECT`, tada treba definirati i stropni prioritet pridijeljen monitoru funkcijom:

```
int pthread_mutex_setprioceiling(pthread_mutex_t *mutex, int prioceiling,
                                 int *old_ceiling);
```

7.6. Ostali mehanizmi sinkronizacije

Osim semafora i monitora, ponekad su prikladniji drugi mehanizmi sinkronizacije, kao što su zaključavanja čitaj/piši, zaključavanja radnim čekanjem (engl. *spinlock*) i barijera.

7.6.1. Zaključavanje čitaj/piši

U mnogim situacijama dretve pristupaju zajedničkom sredstvu samo za dohvat podataka ("čitanje"), a rijetko za promjenu ("pisanje"). U takvim situacijama efikasnije je koristiti zaključavanja za čitanje i pisanje, kod kojih više dretvi može istovremeno zaključati jedan ključ za čitanje. Zaključavanje za pisanje mora biti ekskluzivno, samo jedan "pisač" može u jednom trenutku zaključati ključ kada on već nije zaključan ni za čitanje ni za pisanje. Osnovna POSIX sučelja za ovakva zaključavanja su:

```
pthread_rwlock_t rwlock = PTHREAD_RWLOCK_INITIALIZER; //statička inicijalizacija
int pthread_rwlock_init(pthread_rwlock_t *rwlock, pthread_rwlockattr_t *attr);
int pthread_rwlock_destroy(pthread_rwlock_t *rwlock);
int pthread_rwlock_rdlock(pthread_rwlock_t *rwlock);
int pthread_rwlock_wrlock(pthread_rwlock_t *rwlock);
int pthread_rwlock_unlock(pthread_rwlock_t *rwlock);
```

Funkcija `pthread_rwlock_rdlock()` će zaključavati ključ za čitanje ako ključ već nije zaključan za pisanje ili neki neka druga dretva već čeka na taj ključ, pokušavajući ga zaključati za pisanje sa `pthread_rwlock_wrlock()`. U protivnom pozivajuća dretva se blokira. Istovremeno više dretvi može isti ključ zaključati za čitanje.

Slično, funkcija `pthread_rwlock_wrlock()` će zaključavati ključ za pisanje ako ključ već nije zaključan za pisanje ili čitanje. U protivnom pozivajuća dretva se blokira. Samo jedna dretva može zaključati jedan ključ za pisanje.

Funkcija `pthread_rwlock_unlock()` otpušta ključ koji je pozivajuća dretva držala nad ključem. Ako je to bilo zaključavanje za čitanje i to je bila zadnja dretva koja je držala takav ključ, onda se ključ otključava, odnosno prvoj blokiranoj dretvi za pisanje (ako postoji) se tada dodjeljuje ključ. Slično, ako je to bilo zaključavanje za pisanje, onda se ključ otključava, odnosno prvoj blokiranoj dretvi (ako postoji) se tada dodjeljuje ključ (ili više njih, ako žele zaključavati za čitanje.

7.6.2. Zaključavanje radnim čekanjem

Do sada opisani sinkronizacijski mehanizmi koriste jezgru OS, barem u situacijama kada neku dretvu treba blokirati. Naime, modernija sučelja nastoje kroz atomarne operacije izvan jezgre ustanoviti je li dretvu treba blokirati ili ne. Ako ne treba, onda dretva nastavlja s radom bez poziva jezgre. U protivnom, ako dretvu treba blokirati poziva se jezgrina funkcija koja će to i napraviti. Opširnije o mehanizmu ostvarenom u Linuxu može se pogledati na [Futex].

Poziv jezgrine funkcije uglavnom se ostvaruje mehanizmom prekida (osim u vrlo jednostavnim sustavima gdje se one izravno pozivaju kao funkcije). Mehanizam prekida donosi puno kućanskih poslova. Naime, potrebno je spremiti kontekst dretve koju se blokira te obnoviti kontekst neke druge dretve koja će nastaviti s radom. Osim tih "vidljivih" operacije, vrlo je vjerojatno da će se i priručni spremnik napuniti podacima dretve na koju se prebacujemo. Pri povratku (odblokiranju) prve dretve na procesor ponovno treba napraviti iste kućanske poslove s istim vidljivim i skrivenim operacijama. Često su te operacije "preskupe", tj. traju više od očekivanog trajanja blokiranja. Stoga se u takvim situacijama može na efikasniji način riješiti sinkronizacija radnim čekanjem. Osnovna pretpostavka za to je da se radi o višeprocesorskim sustavim i da su kritični odsječci koji se zaključavanjem štite vrlo kratki. U takvim situacijama efikasnije je radnim čekanjem pričekati da dretva koja je ključ zaključala (i izvodi se na nekom drugom procesoru) isti i otključa. POSIX sučelja za zaključavanje radnim čekanjem su:

```
int pthread_spin_init(pthread_spinlock_t *lock, int pshared);
int pthread_spin_destroy(pthread_spinlock_t *lock);
```

```
int pthread_spin_lock(pthread_spinlock_t *lock);
int pthread_spin_unlock(pthread_spinlock_t *lock);
```

7.6.3. Barijera

Često dretve rade na dijelu problema i ako su prije gotove, prije nastavka rada ipak trebaju pričekati da i ostale dretve završe na svojim dijelovima. Mehanizam barijere je optimalan u takvom slučaju. POSIX sučelja za rad s barijerom su:

```
int pthread_barrier_init(pthread_barrier_t *barrier,
    const pthread_barrierattr_t *attr, unsigned count);
int pthread_barrier_destroy(pthread_barrier_t *barrier);
int pthread_barrier_wait(pthread_barrier_t *barrier);
```

Barijeru je potrebno početno inicijalizirati na broj dretvi (`count`). Dok toliko dretvi ne pozove `pthread_barrier_wait()` svi ti pozivi blokiraju. Zadnja dretva koja pozove tu funkciju odblokira i sve ostale dretve te resetira barijeru (ponovno se dretve preko nje mogu sinkornizirati na isti način).

7.7. Signali

Signali, kao mehanizam operacijskog sustava, su jedan od načina asinkrone komunikacije među dretvama, ali i način s kojim se dretvama mogu "dojaviti" razni događaji koje otkriva operacijski sustav. Dretve koje prime signal mogu tada (u tom trenutku) reagirati, primjerice privremeno prekinuti s trenutnim poslom (nizom instrukcija) te pozvati funkciju za obradu tog događaja. Po obradi događaja dretva se vraća prijašnjem poslu (nastavlja gdje je stala prije nego li je bila prekinuta).

Dretva koja prima signal na njega može reagirati tako da:

- prihvati signal i obradi ga zadanom funkcijom (postavljenoj pri inicijalizaciji prihvata signala)
- prihvati signal i obradi ga pretpostavljenom funkcijom (definiranom u bibliotekama koje koristi program; najčešće je to prekid izvođenja dretve)
- privremeno ignorira signal (signal ostaje na čekanju)
- odbacuje signal (ne poduzima nikakve akcije na njega, niti ga pamti).

Sučelje za signale uključuje operacije nad dretvama i procesima. Kada se radio o sučelju za procese, tada je najčešće aktivna početna dretva procesa (ona dobiva signale upućene procesu).

Osnovne funkcije za upravljanje signalima su:

```
int sigaction(int sig, const struct sigaction *act, struct sigaction *oact);
int kill(pid_t pid, int sig);
int pthread_kill(pthread_t thread, int sig);
int raise(int sig);
int sigqueue(pid_t pid, int signo, const union sigval value);
int pthread_sigqueue(pthread_t thread, int sig, const union sigval value);
```

Pozivi `*sigqueue` omogućavaju slanje signala uz koje ide i dodatna informacija. Za prihvat takvih signala funkcija za obradu mora imati dodatne parametre, npr. prema:

```
void obrada_signala(int signum, siginfo_t *info, void *context);
```

ili takve signale dohvaćati funkcijom:

```
int sigwaitinfo(const sigset_t *set, siginfo_t *info);
```

Mnogi mehanizmi se zasnivaju na signalima. Primjerice, signali se koriste za ostvarivanje odgode izvođenja, periodičko pokretanje, dojavu promjena na ulazno-izlaznim napravama.

Ipak, pri korištenju signala na (starijim) sustavima koji nisu predviđeni za rad u stvarnom vremenu, treba biti oprezan, zato što mnoge funkcionalnosti koje definira POSIX ne moraju biti do kraja ostvarene. Nadalje, signali prekidaju neke jezgrine funkcije, tj. ako je dretva bila blokirana nekom jezgrinom funkcijom (npr. odgoda, sinkronizacija, komunikacija s UI napravama) moguće je da će signal upućen takvoj dretvi prekinuti to blokirano stanje (nakon obrade signala). Za detalje je potrebno pogledati upute uz svaku jezgrinu funkciju zasebno.

Isječak kôda 7.1. Primjer korištenja signala

```
#include <stdio.h>
#include <signal.h>
#include <unistd.h>
#include <pthread.h>

void obrada_signala(int sig, siginfo_t *info, void *context);
void *posao_dretve(void *p);

static pid_t pid_roditelja;
static pthread_t opisnik_glavne_dretve;

int main ()
{
    struct sigaction act;
    sigset_t sigmask;
    pthread_t opisnik_dretve;
    siginfo_t info;

    pid_roditelja = getpid();
    opisnik_glavne_dretve = pthread_self();

    /* stvori dretvu koja salje signale */
    pthread_create(&opisnik_dretve, NULL, posao_dretve, NULL);

    /* postavi da se signal SIGUSR1 obradjuje funkcijom */
    act.sa_sigaction = obrada_signala;
    sigemptyset(&act.sa_mask);
    act.sa_flags = SA_SIGINFO;
    sigaction(SIGUSR1, &act, NULL);

    /* maskiraj signal SIGUSR2 (dohvaćaj ga sa sigwait) */
    sigemptyset(&sigmask);
    sigaddset(&sigmask, SIGUSR2);
    pthread_sigmask(SIG_BLOCK, &sigmask, NULL);

    printf("[Glavna dretva] cekam na SIGUSR2\n");

    while(sigwaitinfo(&sigmask, &info) == -1)
        perror("sigwaitinfo"); /* interrupted with SIGUSR1? */

    printf("[Glavna dretva] primljen signal %d", info.si_signo);
    if (info.si_code == SI_QUEUE)
        printf(" [.sival_int = %d / .sival_ptr = %p]\n",
            info.si_value.sival_int, info.si_value.sival_ptr);
    else
        printf("\n");

    pthread_join(opisnik_dretve, NULL);
```

```
    return 0;
}

void obrada_signala(int sig, siginfo_t *info, void *context)
{
    int j;

    printf("[Obrada signala] zapocela obrada za signal %d", sig);
    if (info != NULL && info->si_code == SI_QUEUE)
        printf(" [.sival_int = %d / .sival_ptr = %p]\n",
            info->si_value.sival_int, info->si_value.sival_ptr);
    else
        printf("\n");

    for (j = 1; j <= 5; j++) {
        printf("[Obrada signala] obradjujem signal %d: %d/5\n", sig, j);
        sleep(1);
    }

    printf("[Obrada signala] zavrsena obrada za signal %d\n", sig);
}


void *posao_dretve(void *p)
{
    union sigval v;

    sigset_t sigmask;
    sigemptyset(&sigmask);
    sigaddset(&sigmask, SIGUSR1);
    sigaddset(&sigmask, SIGUSR2);
    pthread_sigmask(SIG_BLOCK, &sigmask, NULL); //blokiraj oba signala
    //ovo je možda bilo i nepotrebno, ovisno o inačici OS-a koji se koristi

    v.sival_ptr = NULL;

    sleep (1);
    printf("[Dretva] saljem SIGUSR1 (glavnoj dretvi)\n");
    pthread_kill(opisnik_glavne_dretve, SIGUSR1);

    sleep (3);
    printf("[Dretva] saljem {SIGUSR1, 1} (procesu)\n");
    v.sival_int = 1;
    sigqueue(pid_roditelja, SIGUSR1, v);

    sleep (10);
    printf("[Dretva] saljem {SIGUSR2, 2} (procesu)\n");
    v.sival_int = 2;
    sigqueue(pid_roditelja, SIGUSR2, v);

    return NULL;
}
```

7.8. Ostvarivanje međudretvene komunikacije

Međudretvena komunikacija najčešće se obavlja korištenjem zajedničkog adresnog prostora procesa, ali i drugim mehanizmima kao što su redovi poruka i cjevovodi. Korištenje zajedničkog adresnog prostora podrazumijeva korištenje sinkronizacijskih mehanizama za ostvarivanje kritičnog odsječka, npr. semafora ili monitora. Redovi poruka i cjevovodi su zasebni mehanizmi

sa zasebnim sučeljima.

7.8.1. Zajednički spremnik

Sve dretve istog procesa dijele cijeli adresni prostor tog procesa – dretve istog procesa mogu razmjenjivati podatke preko varijabli i objekata u tom procesu. Međutim, dretve različitih procesa za ostvarenje istog načina komunikacije trebaju korištenjem operacijskog sustava uspostaviti dio spremnika koji će biti dostupan dretvama oba procesa – zajednički spremnički prostor (engl. *shared memory*). Sučelja za to postoje u većini sustava i zasnivaju se na raznim načelima. Jedan od takvih načela jest preslikavanje datoteka u radni spremnik procesa, kod kojeg se najprije stvori posebna vrsta datoteke i nju mapira u radni spremnik svih procesa koji žele zajedno komunicirati.

Skup sučelja za ostvarenje navedena načina korištenja zajedničkog spremnika sastoji se od:

```
/* stvaranje objekta zajedničkog spremnika */
int shm_open(const char *name, int oflag, mode_t mode);

/* brisanje objekta zajedničkog spremnika */
int shm_unlink(const char *name);

/* postavljanje veličine datoteke (pa i zajedničkog spremnika) */
int ftruncate(int fildes, off_t length);

/* preslikavanje (mapiranje) datoteke u adresni prostor procesa */
void *mmap(void *addr, size_t len, int prot, int flags, int fildes, off_t off);

/* odvajanje preslikanog dijela spremnika od adresnog prostora procesa */
int munmap(void *addr, size_t len);
```

Isječak kôda 7.2. Primjer korištenja zajedničkog spremnika

```
#include <stdio.h>
#include <stdlib.h>
#include <unistd.h>
#include <sys/mman.h>
#include <sys/wait.h>
#include <fcntl.h>

struct dijeljeno {
    int a, b;
};

#define NAZIV_ZAJ_SPREMNIKA  "/fibonacci"  /* napravljno u /dev/shm/ */
#define VELICINA  sizeof (struct dijeljeno)
#define BROJ_PROCESA 10

void posao_procesa(int proc_id);

int main(void)
{
    int i;

    for (i = 0; i < BROJ_PROCESA; i++)
        if (!fork()) {
            posao_procesa (i);
            exit (0);
        }
    for (i = 0; i < BROJ_PROCESA; i++)
        wait (NULL);
```

```
    return 0;
}

void posao_procesa(int proc_id)
{
    int id;
    struct dijeljeno *x;

    sleep(proc_id); /* svaki novi proces kreće sekundu kasnije */

    id = shm_open(NAZIV_ZAJ_SPREMNIKA, O_CREAT | O_RDWR, 00600);
    if (id == -1 || ftruncate(id, VELICINA) == -1) {
        perror("shm_open/ftruncate");
        exit(1);
    }
    x = mmap(NULL, VELICINA, PROT_READ | PROT_WRITE, MAP_SHARED, id, 0);
    if (x == (void *) -1) {
        perror("mmap");
        exit(1);
    }
    close(id);

    if (proc_id == 0) {
        x->a = 0;
        x->b = 1;
    } else {
        x->b += x->a;
        x->a = x->b - x->a;
    }
    printf("[%d] %d\n", proc_id+1, x->b);

    munmap(x, VELICINA);

    /* zadnji proces briše zajednički spremnik */
    if (proc_id == BROJ_PROCESA-1) {
        shm_unlink(NAZIV_ZAJ_SPREMNIKA);
    }
    /* ako se ne obriše, segment ostaje zauzet */
}
```

7.8.2. Redovi poruka

Komunikacija porukama je najjednostavniji i stoga vrlo često korišteni način komunikacije među dretvama u operacijskim sustavima za SRSV-e. Poruke koje se razmjenjuju u SRSV-ima su često vrlo kratke i sa samo se jednim pozivom mogu poslati. U operacijskim sustavima za SRSV često se poruke mogu poslati izravno dretvama, tj. uz svaku se dretvu stvara i red poruka pridružen toj dretvi, u koji joj druge dretve ili OS šalje poruke.

Komunikacija redom poruka započinje stvaranjem reda poruka (ili spajanjem na postojeći). Nakon toga se u red šalju poruke i iz njega čitaju. Svaka poruka osim korisnog sadržaja može biti označena i tipom poruke (tj. prioritetom kod POSIX-a).

Osnovna sučelja za rad s redom poruka su:

```
mqd_t mq_open(const char *name, int oflag);
mqd_t mq_open(const char *name, int oflag, mode_t mode, struct mq_attr *attr);
int mq_send(mqd_t mqdes, const char *msg_ptr, size_t msg_len, unsigned msg_prio);
ssize_t mq_receive(mqd_t mqdes, char *msg_ptr, size_t msg_len, unsigned *msg_prio);
```

Sučelje `mq_open` s više parametara mora se koristiti pri stvaranju reda, dok se ono kraće može

koristiti ako red već postoji. Parametar `msg_prio` kod `mq_send` definira prioritet poruke. Red poruka je složen prema prioritetu - pri čitanju iz reda uzima se prva poruka – ona najveća prioriteta.

Isječak kôda 7.3. Primjer korištenja reda poruka

```
#include <stdio.h>
#include <stdlib.h>
#include <string.h>
#include <unistd.h>
#include <mqueue.h>
#include <sys/wait.h>
#include <fcntl.h>

#define NAZIV_REDA           "/msgq_example_name"
#define MAX_PORUKA_U_REDU    5
#define MAX_VELICINA_PORUKE  20

int proizvodjac();
int potrosac();

int main(void)
{
    proizvodjac();

    sleep(1);
    if (!fork()) {
        potrosac();
        exit(0);
    }
    wait(NULL);

    mq_unlink(NAZIV_REDA);

    return 0;
}

int proizvodjac()
{
    mqd_t opisnik_reda;
    struct mq_attr attr;
    char poruka[] = "primjer sadrzaja";
    size_t duljina = strlen (poruka) + 1;
    unsigned prioritet = 10;

    attr.mq_flags = 0;
    attr.mq_maxmsg = MAX_PORUKA_U_REDU;
    attr.mq_msgsize = MAX_VELICINA_PORUKE;
    opisnik_reda = mq_open(NAZIV_REDA, O_WRONLY | O_CREAT, 00600, &attr);
    if (opisnik_reda == (mqd_t) -1) {
        perror("proizvodjac:mq_open");
        return -1;
    }
    if (mq_send(opisnik_reda, poruka, duljina, prioritet)) {
        perror("mq_send");
        return -1;
    }
    printf("Poslano: %s [prio=%d]\n", poruka, prioritet);

    return 0;
}

int potrosac()
```

```
{
    mqd_t opisnik_reda;
    char poruka[MAX_VELICINA_PORUKE];
    size_t duljina;
    unsigned prioritet;

    opisnik_reda = mq_open(NAZIV_REDA, O_RDONLY);
    if (opisnik_reda == (mqd_t) -1) {
        perror("potrosac:mq_open");
        return -1;
    }
    duljina = mq_receive(opisnik_reda, poruka, MAX_VELICINA_PORUKE,
                         &prioritet);
    if (duljina < 0) {
        perror("mq_receive");
        return -1;
    }
    printf("Primljeno: %s [prio=%d]\n", poruka, prioritet);

    return 0;
}
```

Funkcije slanja i primanja mogu blokirati pozivajuću dretvu, ako je red pun ili prazan. Zato postoje i dodatne funkcije s ograničenim vremenom blokiranja (koje imaju `timed` u imenu).

7.8.3. Cjevovodi

Za razliku od poruka gdje u redu poruka postoji granulacija podataka – jedinica podataka je poruka (zadana zaglavljem), kod cjevovoda takve granulacije nema. Novi podaci se nadodaju na kraj starih. Zbog nepostojanja dodatnog zaglavlja cjevovodi su pogodniji kada treba prenijeti veću količinu podataka.

Rad sa cjevovodima je gotovo identičan radu s datotekama. Iz njih se može čitati i u njih se mogu upisivati podaci. Cjev ima dvije strane: ulaznu i izlaznu. Svaka od njih ima svoj opisnik koji je identičan opisniku datoteke te se s njima radi i kao s datotekama. Dapače, cjevovod može imati i ime u datotečnom sustavu (imenovani cjevovod). U komunikaciji među dretvama istog procesa cjevovod se može stvoriti i dinamički, pozivom `pipe`, bez da mu se dodaje ime u datotečnom sustavu (neimenovani cjevovod).

Sučelje za rad sa cjevovodima su ista kao i za rad s datotekama (uz par iznimaka), uz dodatak sučelja `pipe` koje stvara novi neimenovani cjevovod. U datotečnom sustavu cjevovod se može napraviti naredbama (ili funkcijom iz programa) `mknod` i `mkfifo`.

Osnovno sučelje za rad sa cjevovodima uključuje:

```
int pipe(int fildes[2]);
int mknod(const char *path, mode_t mode, dev_t dev);
int mkfifo(const char *path, mode_t mode);
int open(const char *path, int oflag, ...);
int close(int fildes);
ssize_t write(int fildes, const void *buf, size_t nbyte);
ssize_t read(int fildes, void *buf, size_t nbyte);
```

Isječak kôda 7.4. Primjer korištenja imenovanog cjevovoda

```
#include <stdio.h>
#include <stdlib.h>
#include <string.h>
#include <unistd.h>
```

```
#include <fcntl.h>
#include <sys/stat.h>
#include <sys/wait.h>

#define NAZIV_CIJEVI  "/tmp/pipe_example"
#define N             50

void citac();

int main()
{
    int fd, i;
    char *poruka[] = { "abcd", "ABC", "12345", "X", NULL };

    if (mkfifo(NAZIV_CIJEVI, S_IWUSR | S_IRUSR))
        perror("pisac:mkfifo"); /* možda već postoji */

    if (fork() == 0)
        citac();

    sleep(1); /* i čitač će zbog ovoga čekati! */
    fd = open(NAZIV_CIJEVI, O_WRONLY); /* čekaj da i čitač otvara */
    if (fd == -1) {
        perror("pisac:open");
        return 1;
    }
    printf("pisac otvorio cijev\n");

    for (i = 0; poruka[i] != NULL; i++)
        write(fd, poruka[i], strlen(poruka[i]));
    close(fd);

    wait(NULL);

    unlink(NAZIV_CIJEVI);

    return 0;
}

void citac()
{
    int fd, i, sz;
    char buffer[N];

    fd = open(NAZIV_CIJEVI, O_RDONLY); /* čekaj da i pisač otvara */
    if (fd == -1) {
        perror("citac:open");
        exit(1);
    }
    printf("citac otvorio cijev\n");

    i = 0;
    memset(buffer, 0, N * sizeof(char));
    while ((sz = read(fd, &buffer[i], N * sizeof(char) - i)) > 0)
        i += sz;
    printf("Primljeno: %s\n", buffer);

    exit(0);
}
```

Načelo cjevovoda se koristi i pri komunikaciji s udaljenim računalima, kada se kao prijenosni protokol koristi spojna usluga (engl. *transmission control protocol – TCP*).

7.9. Korištenje višedretvenosti u SRSV-ima

Operacijski sustavi (barem oni namijenjeni SRSV-ima) imaju mogućnosti koje se mogu iskoristiti za ostvarenje SRSV-a. Ipak, pri ostvarivanju takvih sustava korištenjem dretvi posebnu pažnju treba posvetiti:

- raspoređivanju dretvi – odabrati prikladne postupke raspoređivanja i njihove parametre
- načinu sinkronizacije – odabrati prikladne mehanizme i paziti na mogućnost pojave potpunog zastoja, inverzije prioriteta, rekurzivnog zaključavanja
- načinima komunikacije – svojstva odabranih mehanizama (blokirajući ili ne, veličina poruke, trajanje prijenosa podataka, način obavještavanja odredišne dretve, . . .)
- korištenju podataka u zajedničkom spremniku – zaštititi sinkronizacijskim mehanizmom
- trošku poziva jezgrinih funkcija – u sustavima u kojim se vrlo često pozivaju jezgrine funkcije i gdje se često obavlja raspoređivanje dretvi (npr. poslovi dretvi između sinkronizacijskih funkcija su vrlo kratki) utjecaj poziva jezgrinih funkcija i (kućanskih) poslova koji se pritom obavljaju, postaje primjetan i može predstavljati problem ako nije uračunat pri osmišljavanju sustava.

Tablica 7.3. prikazuje neke mogućnosti odabira u kontekstu višedretvena ostvarenja upravljanja.

Tablica 7.3. Neki od mehanizama operacijskog sustava za potporu višedretrvenosti

mehanizam	**uobičajeni odabir**	**dodatne mogućnosti**
raspoređivanje	raspoređivanje prema prioritetu SCHED_FIFO SCHED_RR	raspoređivanje prema krajnjim trenucima dovršetaka – SCHED_DEADLINE raspoređivanje sporadičnih zadataka – SCHED_SPORADIC
sinkronizacija	semafori monitori	operacije *probaj_čekati*, *čekaj_ograničeno* (npr. `sem_trywait`, `sem_timedwait`) rekurzivno zaključavanje nasljeđivanje prioriteta stropni prioritet
komunikacija	zajednički spremnik redovi poruka cjevovodi	signali datoteke mrežna komunikacija

Višedretvenost je moćan koncept, ali ga treba oprezno koristiti.

Pitanja za vježbu 7

1. Navesti osnovne mehanizme za sinkronizaciju dretvi?
2. Što je to potpuni zastoj? Kad se može pojaviti? Kako se izbjegava?
3. Što je to rekurzivno zaključavanje i zašto je ponekad potrebno?

4. Na primjeru prikazati nastajanje problema inverzije prioriteta.
5. Opisati izvorni protokol stropnog prioriteta te njegovo pojednostavljenje.
6. Opisati protokol nasljeđivanja prioriteta. Prikazati rad protokola nad primjerima.
7. Nad kojim sinkronizacijskim mehanizmima definiranih POSIX normom su podržani protokoli stropnog prioriteta te protokol nasljeđivanja prioriteta?
8. Opisati mehanizam signala. Koji se problemi mogu javiti u korištenju signala (a na koje treba pripaziti, odnosno, što treba istražiti kod operacijskog sustava i njegovog upravljanja signalima).
9. Opisati osnovna načela i svojstva međudretvene komunikacije korištenjem mehanizama zajedničkog spremnika, reda poruka, cjevovoda i signala. Kada koristiti pojedine mehanizme?
10. Od svih međudretvenih komunikacijskih mehanizama, koji se najčešće koristi u SRSV-ima? Zašto?
11. Osim uobičajenih Čekaj*/Pročitaj*, Postavi*/Pošalji* sinkronizacijskih i komunikacijskih funkcija s uobičajenim ponašanjem, koje se dodatne operacije i proširenja zahtijevaju od takvih funkcija u kontekstu korištenja u SRSV-ima?
12. Što se sve može dogoditi s dretvom pri izvođenju koda (očekivano i neočekivano)?

```
struct timespec t;
t.tv_sec = 0; t.tv_nsec = 100000; /* 100 mikrosekundi */
clock_nanosleep ( CLOCK_REALTIME, 0, &t, NULL ); /* odgodi za t */
```

13. U nekom sustavu javljaju se dretve: D_1 u $t_1 = 0$ ms, D_2 u $t_2 = 3$ ms te D_3 u $t_3 = 6$ ms. Svaka dretva sastoji se od tri dijela posla: A, B i C. Izvođenje A dijela traje 2 ms, B dijela 3 ms te C dijela 2 ms. Prije izvođenja B dijela dretve trebaju zauzeti semafore: dretva D_1 semafor S_1, dretva D_2 semafor S_2, dretva D_3 semafor S_1. Dretva D_3 ima najveći prioritet, dok dretva D_1 ima najmanji. Ako se koristi protokol nasljeđivanja prioriteta pokazati izvođenje zadanih dretvi, tj. što procesor radi u pojedinom trenutku, dok sve dretve ne završe sa svojim poslovima.
14. Za neki sustav poznati su događaji pokretanja dretvi, njihovi poslovi i trajanja.
    U $t = 1$ pokreće se dretva D_1. Nakon 1 ms rada dretva treba zauzeti semafor S_1. Nakon još 2 ms rada (uz semafor S_1) treba semafor S_2. Nakon još 1 ms rada (uz semafore S_1 i S_2) otpušta oba semafora. Nakon još 1 ms rada dretva završava. Ukupno, dretva treba 5 ms procesorskog vremena.
    U $t = 3$ pokreće se dretva D_2. Nakon 1 ms rada treba zauzeti semafor S_2. Nakon još 2 ms rada (uz semafor S_2) treba semafor S_3. Nakon još 1 ms rada (uz semafore S_2 i S_3) otpušta oba semafora. Nakon još 1 ms rada dretva završava. Ukupno, dretva treba 5 ms procesorskog vremena.
    U $t = 5$ pokreće se dretva D_3. Nakon 1 ms rada treba zauzeti semafor S_3. Nakon još 2 ms rada (uz semafor S_3) treba semafor S_1. Nakon još 1 ms rada (uz semafore S_1 i S_3) otpušta oba semafora. Nakon još 1 ms rada dretva završava. Ukupno, dretva treba 5 ms procesorskog vremena.
    Dretva D_3 ima najveći prioritet, slijedi D_2 dok D_1 ima najmanji prioritet. Prikazati rad sustava dretvi na jednoprocesorskom sustavu koji koristi prioritetno raspoređivanje te:
    a) nikakve druge protokole (niti nasljeđivanje prioriteta niti stropne protokole)
    b) ako koristi protokol nasljeđivanja prioriteta

c) ako koristi jednostavniju inačicu protokola stropnog prioriteta

d) ako koristi izvorni protokol stropnog prioriteta.

15. Dretve $D_1 - D_4$ koriste semafor S po 100 ms, ali ne odmah po pokretanju već nakon 50 ms rada (svaka dretva najprije nešto radi 50 ms pa onda hoće semafor S za idućih 100 ms). Nakon otpuštanja semafora dretve rade nešto još 50 ms (dakle ukupno 50+100+50, svaka dretva). Dretva D_2 javlja se prva u $t = 0$ ms. Slijedi D_3 u $t = 100$, D_4 u $t = 100$ te D_1 u $t = 150$. Prioritet dretvi određen je njenim indeksom: D_4 ima najveći a D_1 namanji prioritet. Ako se dretve izvode na dvoprocesorskom sustavu i koristi se protokol nasljeđivanja prioriteta (uz prioritetni raspoređivač), pokazati rad sustava.

16. U nekom jednoprocesorskom sustavu izvode se dretve A, B, C i D. Dretva A ima najveći prioritet, slijedi dretva B, pa C te D koja ima najmanji. Dretve koriste tri sredstva koja su zaštićena semaforima S_1, S_2 i S_3. Sve dretve mogu trebati bilo koje sredstvo u svom izvođenju. Ponekad, dretva koja već ima jedno sredstvo može tražiti i drugo, ali ne i treće (prije traženja trećeg otpušta sva zauzeta). Pretpostavka je da se potpuni zastoj neće dogoditi. Kada neka dretva zauzme sredstvo, ona ga ne koristi (aktivno) dulje od 10 μs. Ako sustav koristi raspoređivanje prema prioritetu te protokol nasljeđivanja prioriteta, koliko se najviše (u najgorem slučaju) može zaustaviti dretva A zbog inverzije prioriteta? Opisati scenarij u kojem se to događa.

8. Raspodijeljeni sustavi

Razmatranje raspodijeljenih SRSV-a zahtjeva dodatne analize veza između raspodijeljenih računala (čvorova sustava) te načina komunikacije a da bi se u takvom dustavu moglo ostvariti vremenski usklađeno upravljanje.

Komunikacija može biti sinkrona, kada se podaci šalju i primaju usklađeno s nekim izvorom takta ili drugim događajima, ili asinkrona, kada se poruke šalju kad se za njima pojavi potreba. Nadalje, podaci koji se prenose mogu biti slani u cjelini ili pak podijeljeni na blokove, koji se u ovom kontekstu nazivaju paketima. Drugi način, korištenjem paketa je češći u nekritičnim sustavima.

Komunikacija se može podijeliti na komunikaciju računala s ulazno-izlaznim jedinicama (periferijom) i komunikaciju između različitih računala. Komunikacija računala s periferijom je zapravo dio protokola komunikacije s raznim uređajima, primjerice RS232 i USB. Periferne naprave rade ono što im se protokolom zada – one ne izvode programe koje programer može pripremiti i prilagoditi pojedinoj okolini (one same mogu imati mikrokontroler, ali on izvodi kod koji je proizvođač u njih upisao i koji se ne mijenja). Stoga se takva komunikacija neće posebno razmatrati u nastavku.

Komunikacija između različitih računala obavlja se korištenjem različitih protokola. Najpoznatiji među njima je svakako protokolni slog Internet, često predstavljen i kraticom TCP/IP koja označava dva najznačajnija protokola u tom slogu: TCP (engl. *transmission control protocol*) na prijenosnom sloju i IP (engl. *internet protocol*) na mrežnom. TCP/IP se sastoji od pet slojeva:

- aplikacijski (primjeri: HTTP, POP3, SMTP, DNS)
- prijenosni (primjeri: TCP, UDP)
- mrežni (primjeri: IPv4, IPv6)
- podatkovni (primjeri: ethernet, IEEE 802.11 (WLAN), PPP)
- fizički (ovisi o podatkovnom, npr. CSMA/CD, RS232).

Zadnji sloj, fizički, se često i ne navodi kao dio protokolnog sloga, već ga se smatra dijelom podatkovnog.

TCP/IP je suviše složen da bi se ovdje detaljnije razmatrao. On je izgrađen da bude robustan te zato ima redundancije u vezama koje se mogu iskoristiti pri većem opterećenju i pri ispadu pojedinih veza/čvorova. Međutim, nije građen s namjerom upravljačkog korištenja u SRSV-ima te u tom kontekstu ima loša vremenska svojstva zbog toga što pokušava sve isporučiti bez da se na to može utjecati.

8.1. Povezivanje računala u mrežu

Način povezivanja među računalima raspodijeljenog sustava ovisi o korištenim protokolima, fizičkoj raspodjeli računala, potrebnim svojstvima i slično. Primjerice, veze mogu biti ostvarene centralizirano, gdje postoji glavno računalo koje upravlja komunikacijom, ili može biti decentralizirano, gdje su svi sudionici u komunikaciji ravnopravni.

Komunikacijska infrastruktura može također biti izvedena na razne načine, svaki sa svojim prednostima i nedostacima, prema slici 8.1. Primjerice, komunikacija “svatko sa svakim” pruža najviše mogućnosti, ali je znatno skuplja od svih ostalih. Kao i svugdje, i ovdje je potrebno

napraviti kompromisno rješenje koje će ipak zadovoljiti zahtjeve. Kada se veza između dva računala (čvora) ne uspostavlja izravno već preko drugih računala, onda se najčešće koristi komunikacija s prosljeđivanjem paketa.

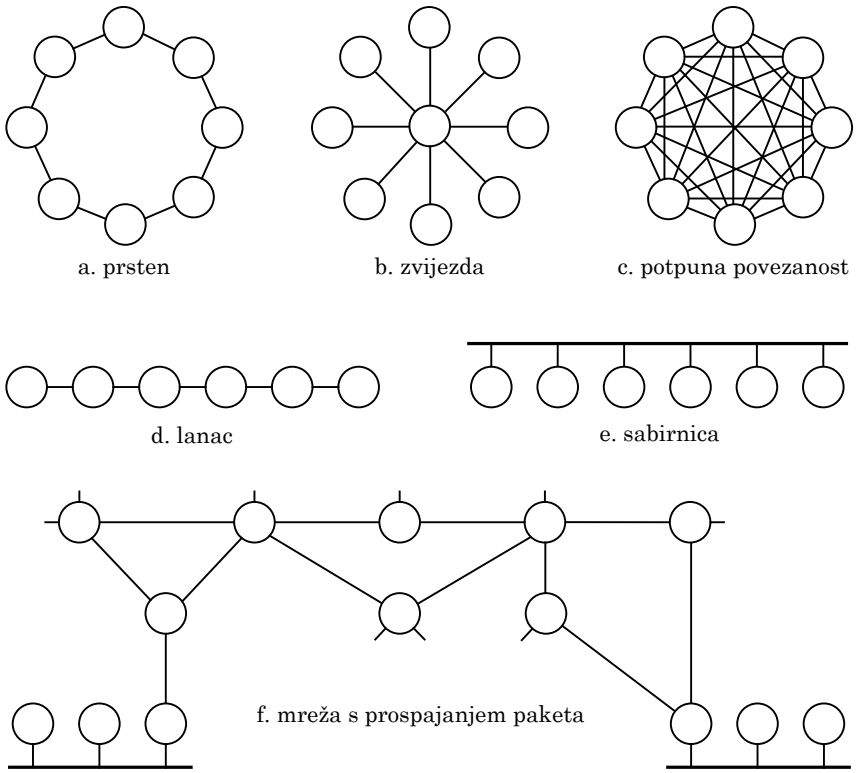

Slika 8.1. Primjeri načina spajanja računala u mreži

Razni SRSV-i koriste razne načina povezivanja. Pri razmatranju nekog sustava treba uzeti u obzir kašnjenja koja korištena mreža stvara i jesu li ona prihvatljiva. Odabir ovisi o potrebama i procjeni projektanta sustava. Kod SRSV-a potrebno je uzeti sigurnosnu granicu, tj. predimenzionirati sustav. Korištenjem standardne mrežne opreme smanjuje se cijena sustava i olakšava razvoj i povezivanje, ali se kvare vremenska svojstva.

Komunikacijski medij može biti parica, koaksijalni kabel, optičko vlakno i slični materijali, ili se komunikacija može obavljati i bežično tamo gdje udaljenost i smetnje nisu zapreka. Protokoli koji se koriste na komunikacijskim medijima mogu biti zasnovani na načelima:

- podjele vremena – svaki čvor dobije svoj dio vremena na mediju
- korištenja značke (tokena) kao oznake prava pristupa čvora mediju
- pojedinačno korištenje zajedničkog medija uz praćenje pristupa mediju (CSMA/CD, CAN).

Svaki od navedenih načela ima svojih prednosti i nedostataka.

8.2. Model komunikacije

Osim fizičkih komponenata, za komunikaciju je potrebna i programska potpora. Iako ona može biti dio programa (u vrlo jednostavnim slučajevima), najčešće se koristi mrežni podsustav operacijskog sustava. Mrežni podsustav ostvaruje protokolni slog i omogućuje korištenje komunikacijskog sustava kroz svoje sučelje.

Slika 8.2. grafički prikazuje model komunikacije koji uključuje procese, operacijski sustav i komunikacijsku infrastrukturu. U ovakvom slojevitom sustavu, svaki sloj može obavljati dodatnu podjelu podataka koju je dobio od višeg sloja, omatati te dijelove dodatnim zaglavljima, koristiti redove za privremenu pohranu i slično, te obratne radnje kod primitka paketa od nižeg sloja, kada radi i provjeru ispravnosti. Sve te radnje traju, i u zbroju s radnjama ostalih čvorova koji sudjeluju u prijenosu mogu narušiti vremenska svojstva.

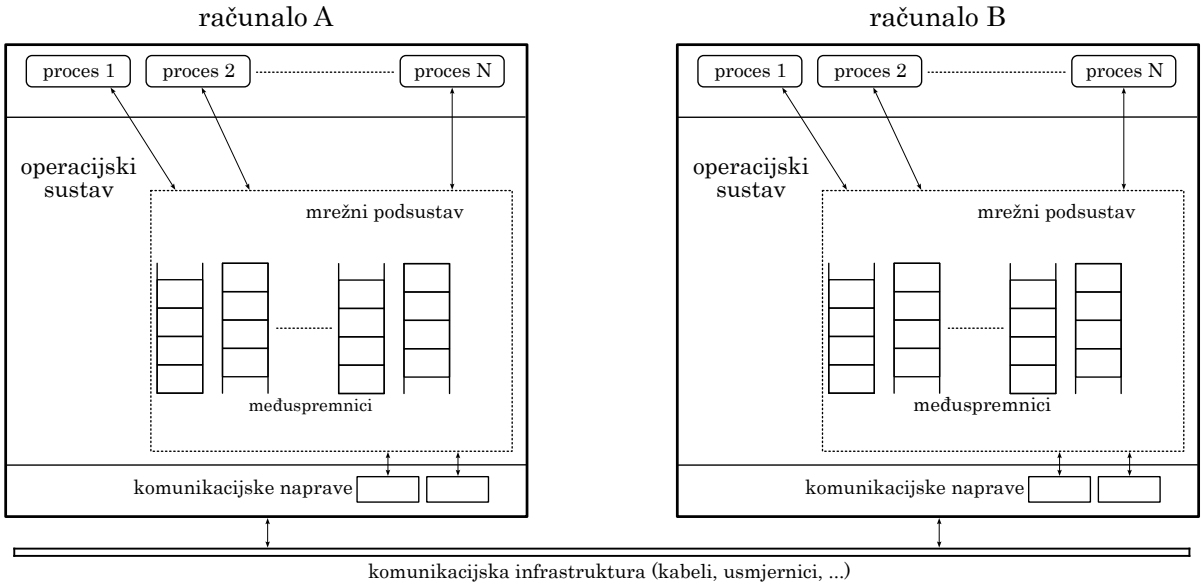

Slika 8.2. Model komunikacije u raspodijeljenom sustavu

8.3. Svojstva komunikacijskog sustava

Pri razmatranju komunikacijskog sustava za uporabu u SRSV treba pogledati njegova svojstva. Posebice treba pripaziti na:

- kašnjenje (engl. *delay*)
- brzinu/propusnost mreže (engl. *throughput, bandwidth*)
- varijacije u kašnjenju (engl. *delay jitter*)
- postotak prekasno pristiglih paketa (engl. *miss rate*)
- postotak izgubljenih paketa (engl. *loss rate*)
- postotak pogrešaka pri prijenosu (engl. *invalid rate*)
- veličinu paketa
- dimenzije mreže (udaljenosti).

Kašnjenje

Jedno od najbitnijih svojstava u okruženju SRSV-a je kašnjenje i definira koliko vremena prolazi od slanja do primanja paketa (na aplikacijskoj razini). Preveliko kašnjenje može uzrokovati kasnu reakciju pojedinog računala te prekoračivanje zadanih vremenskih ograničenja. Uzroci kašnjenja su u mediju prijenosa (npr. ograničenje brzine svjetlosti), ali u značajnoj mjeri i svojstvima računala koja šalju, primaju i prenose podatke, koji obavljaju operacije stavljanja poruka u redove, obrade poruka (čitaju zaglavlja, provjeravaju ispravnost).

Varijacije u kašnjenju

Samo kašnjenje, koje može biti izračunato kao prosječna vrijednost kašnjenja svih paketa, nije dovoljna za analizu primjenjivosti u SRSV-ima. Ako je kašnjenje vrlo promjenjivo, čak i ako se duža kašnjenja javljaju rijetko, komunikacijski sustav ne mora biti prihvatljiv, pogotovo za stroge SRSV-e.

Greške u prijenosu

Prekasno pristigli paketi, kao i oni koji su izgubljeni ili imaju grešku, često zahtjevaju retransmisiju – polazni čvor ih mora ponovno poslati. Iznimka su slučajevi kada je povremeni gubitak prihvatljiv, kao kod prijenosa slike i zvuka. Grešku u prijenosu treba prvo ustanoviti: pošiljalac će ustanoviti da nije primio odgovor na poslati paket tek nakon isteka zadanog vremena čekanja na dogovor, i tek će tada ponovno poslati paket (ako je takav protokol). Greška zato uzrokuje značajnija kašnjenja i time narušava vremenska svojstva komunikacije.

Propusnost

Propusnost mreže definira koliko podataka se može prenijeti u jedinici vremena. Propusnost je među važnijim svojstvima uobičajenih računalnih mreža. Međutim, sa stanovišta SRSV-a, propusnost je bitnija jedino u multimedijskim primjenama, radi kvalitete prijenosa slike i zvuka u stvarnom vremenu. U pogledu upravljanja sustavima, propusnost je manje bitna jer su upravljačke poruke uglavnom kratke i nije potrebna velika propusnost već je bitnije vrijeme pristizanja poruke do željenog čvora, tj. potrebno je kratko vrijeme kašnjenja.

Propusnost i kašnjenje ne moraju biti proporcionalni. Velika propusnost ne mora značiti i kratko kašnjenje, iako to često i je. Primjerice, čitanje podataka s tvrdog diska može doseći velike brzine (i do stotinjak MB u sekundi), ali za dohvat pojedinačnog (nasumičnog) podatka treba ponekad čekati i desetak milisekundi i više.

Unutarnja struktura komunikacijskog sustava je složena tematika te se ovdje neće u nju ulaziti i raspravljati o razlozima kašnjenja, grešaka i drugih problema koji se mogu pojaviti.

8.4. Primjeri protokola osmišljenih za komunikaciju u stvarnom vremenu

Prikažimo ukratko svojstva dva protokola, jednog na nižoj razini (podatkovnoj) i jednog na aplikacijskoj razini.

8.4.1. Controller Area Network

Protokol koji se često koristi u sustavima upravljanja jest *Controller Area Network* (CAN). CAN je značajno jednostavniji od primjerice TCP/IP zasnovane mreže, ne koristi slojeve unutar sebe. Kod CAN-a se koristi zajednički medij (sabirnica), brzine do 1 Mbit/s i najveće duljine do 50 metara. Fizički se koriste dva vodiča preko kojih se ista informacija prenosi ali različitim naponima (CAN visoko i CAN nisko). Svi čvorovi spojeni na tu mrežu mogu slati i primati poruke. Poruke imaju definirani format, ali mogu biti promjenjive duljine. Umjesto adresiranja polazišta i odredišta, svaka poruka započinje s identifikatorom, 11-bitovnim brojem. Pojedini čvorovi čitaju i koriste poruke s određenim identifikatorom, a ostale ignoriraju. Kao i kod CSMA/CD protokola, čvor prije slanja osluškuje sabirnicu i tek kad je ona slobodna započinje sa slanjem. Kada se dogodi da dva čvora istovremeno započinju sa slanjem poruka, onda se koristi svojstvo dominantnog bita – bita 0. Naime, s obzirom na to da svaka poruka započinje identifikatorom, on se koristi za oznaku prioriteta poruke. Čvor koji šalje manje prioritetnu poruku primijetit će da je na sabirnici njegov identifikator nadjačan prioritetnijom porukom te će u tom trenutku zaustaviti slanje i prepustiti sabirnicu prioritetnijoj poruci koja će biti poslana do kraja bez prekidanje i greške.

Primjer 8.1.

Pretpostavimo da dva čvora istovremeno započinju sa slanjem svojih poruka, prvi s identifikatorom 57, a drugi s 43. S obzirom na to da manji broj predstavlja veći prioritet, druga poruka treba biti prioritetnija. Binarno, identifikatori su:

$$57_{10} = 00000\underline{1}1001_2 \tag{8.1.}$$

$$43_{10} = 00000\underline{0}1011_2 \tag{8.2.}$$

Prvi čvor će tek pri slanju 7. bita primijetiti da poslano ne odgovara očitanom na sabirnici te će on tada prestati slati, dok će drugi čvor svoju poruku poslati do kraja.

Poruke se, osim početnog identifikatora, sastoje od upravljačkog zaglavlja i podataka. Poruke po tipu mogu biti podatkovne, zahtjevi za podacima (engl. *remote*), poruke o greškama (engl. *error*) te poruke preopterećenja (engl. *overload*).

CAN ima malu iskoristivost prijenosnog medija, ali zato osigurava isporuke uz poštivanje vremenskog ograničenja.

Osim prioriteta ugrađenog u protokol, CAN primjenjuje i druge postupke zbog kojih ostvaruje svojstva prikladna za upravljačke sustave kao što su:

- prioritetna shema poruka
- jamstvo da kašnjenje neće biti iznad definiranog
- prilagodljivo podešavanje (nije čak ni neophodno)
- slanje prema više čvorova (engl. *multicast*)
- osiguravanje konzistencije podataka
- ugrađeni postupci otkrivanja grešaka i njihovo signaliziranje
- automatizirana retransmisija kao opcija
- razlikovanje privremene greške od kvarova u čvorovima (koji se tada mogu i isključiti).

CAN sabirnica je zbog svojih svojstava vrlo popularan izbor za komunikaciju u upravljačkim

sustavima (primjerice automobilima), iako je patentirana i potrebno je kupiti licencu za uporabu.

8.4.2. RTP/RTCP

Prijenos multimedije nije kritičan posao i uglavnom se ništa tragično neće dogoditi ako bude problema u prijenosu. Međutim, taj prijenos posjeduje svojstva SRSV-a jer se mora obavljati u stvarnom vremenu i (skoro) svaka se greška primjećuje. Ako dotok podataka nije pravilan primjetit će se problemi u slici i zvuku.

TCP kao prijenosni protokol nudi pouzdanu uslugu prijenosa podatka, sam se brine za probleme pri prijenosu (izgubljeni paketi, paketi s greškama i slično) i višim slojevima nudi pouzdanu uslugu prijenosa podataka. Međutim, ima vrlo malo mogućnosti za upravljanje vremenskim svojstvima prijenosa čime u sustav unosi nedeterminističko ponašanje bez mogućnosti upravljanja u vremenski kritičnim situacijama.

Prikladnim postupcima se i nad lošim komunikacijskim kanalom (s puno grešaka) može ostvariti prihvatljiva komunikacija koja može zadovoljavati i neke primjene za SRSV-e, ali ne s TCP-om.

Mnogo bolji izbor za uporabu u SRSV-ima jest UDP (engl. *user datagram protocol*). On ne pruža pouzdan prijenos podataka, ali upravo zato omogućuje znatno više kontrole koja se ostvaruje iznad njega. Automatske retransmisije ugrađene u TCP u SRSV-ima zapravo smetaju. Kada dođe do problema, mi ga želimo rješiti na prikladan način, što ne mora uvijek biti retransmisija kao kod TCP-a. Primjerice, kod multimedije, možda se poneka slika (engl. *frame*) može i izbaciti, bez potrebe retransmisije, a da kvaliteta videokonferencije i dalje bude zadovoljavajuća. Retransmisija bi možda previše zadržavala video signal i time smanjila mogućnosti komunikacije u stvarnom vremenu.

RTP (engl. *real time protocol*) i RTCP (engl. *real time control protocol*) osmišljeni su upravo za prijenos multimedije, za videokonferencije, za interaktivne multimedijalne aplikacije, za raspodijeljene simulacije. Za svoje ostvarenje koriste UDP. RTP prenosi podatke dok RTCP služi za upravljanje prijenosom. Svaka komponenta multimedije se zasebno prenosi, u zasebnom RTP kanalu koji koristi zasebnu pristupnu točku (engl. *port*) u mrežnom podsustavu. RTCP koristi zasebnu pristupnu točku, ne dijeli ju s RTP-om.

RTP/RTCP omogućava dinamičko dodavanje sudionika u komunikaciji, kao i dinamičku promjenu svojstava komunikacije (svojstva audio i video signala koji se prenose). Osim čvorova koji su izvori podataka i čvorova koji podatke primaju, u sustavu mogu biti i dodatni pomoćni čvorovi koji ili samo prenose podatke ili koji ih pritom i prilagođavaju (mikseri, translatori).

Pri prijenosu multimedije, zvuk i slika se šalju odvojenim kanalima. U podatke (sekvence) koji se prenose preko tih kanala se ugrađuju identifikatori izvora, vremenske oznake, redni brojevi i opis formata. U jednoj sjednici (engl. *multicast group*) može biti i do nekoliko tisuća sudionika.

RTCP koristi zasebni kanal po svakom RTP kanalu. Preko RTCP se šalju upravljački paketi koji opisuju kvalitetu primljenog sadržaja (engl. *reception quality*). Izvori podataka (i mikseri i translatori) na osnovu tih podataka zaključuju o mogućim problemima u prijenosu te prilagođavaju idući promet preko RTP kanala. Svaki čvor bi trebao povremeno slati izvješća preko RTCP kanala koji uobičajeno sadrže informacije o učinkovitosti prijenosa: koliko se paketa izgubi, kolika su vremena kašnjenja i varijacije tog kašnjenja i slično. Da RTCP ne bi zagušio komunikacijsku vezu, za njega se rezervira samo mali dio propusnosti (npr. do 5%). Učestalost slanja RTCP paketa ovisi i o veličini grupe, svojstvima mreže i broju sudionika u komunikaciji.

8.5. Sinkronizacija vremena u raspodijeljenim sustavima

U raspodijeljenim sustavima, osim osiguranja lokalne vremenske ispravnosti, potrebno je osigurati i zajedničku (globalnu) vremensku ispravnost sustava.

Na razini raspodijeljenog sustava, ponekad je dovoljna razina ispravnosti vremenska uređenost događaja – da se uvijek može uspostaviti koji se događaj dogodio prije, a koji poslije. U tu svrhu mogu se koristiti odgovarajući protokoli, primjerice raspodijeljeni Lamportov algoritam, ili njegova pojednostavljenja (protokol Ricarta i Agrawala) ili slični.

Često samo uspostava relacija između događaja nije dovoljna, već je potrebno vremenski usklađeno upravljati raznim elementima sustava iz različitih čvorova, tj. računala u tim čvorovima. Međutim, satovi u tim čvorovima ne moraju biti uvijek usklađeni, odnosno čak i ako jesu u nekom trenutku usklađeni, zbog nepreciznosti satnih mehanizama oni će se u budućnosti pomaknuti.

Usklađivanje sata može se obaviti korištenjem vanjskog izvora sata, primjerice preko nekog poslužitelja koji daje "koordinirano svjetsko vrijeme" (engl. *Coordinated Universal Time – UTC*) te se to vrijeme uskladi s lokacijom čvora (Hrvatska je u zoni UTC+1). Preciznije usklađivanje može koristiti izvor sa satelita, primjerice GPS-a.

Ako se usklađivanje obavlja preko mreže kao što je to Internet, postavlja se pitanje kako riješiti probleme koje će sama mreža unijeti. Naime, kada bi prijenos podataka bio trenutan, tada bi vrijeme koje se dobije od poslužitelja odmah mogli postaviti u sat klijenta. Međutim, vrijeme potrebno paketu s informacijom o točnom vremenu da stigne do klijenta nije jednako nuli. Štoviše, to vrijeme može biti različito u različitim trenucima s obzirom na to da paket može putovati raznim granama mreže, a i brzina pojedinih grana može se vremenom mijenjati (primjerice zbog različita opterećenja mreže). Kako izmjeriti kašnjenje i uzeti ga u obzir pri usklađivanju sata klijenta sa satom poslužitelja?

Jedan od jednostavnih načina sinkronizacije vremena s udaljenim poslužiteljem može se ostvariti uz pretpostavku simetrične veze, tj. veze kod koje je trajanje puta paketa u jednom i drugom smjeru isto. Neka se pri komunikaciji za sinkronizaciju sata klijenta sa satom poslužitelja koriste sljedeći zapisi o vremenima, koji se dodaju u podatke sinkronizacije:

1. t_1^k – vrijeme slanja zahtjeva, po satu klijenta (satu kojeg treba uskladiti)
2. t_2^p – vrijeme primitka zahtjeva, po satu poslužitelja (satu s kojim se treba uskladiti)
3. t_3^p – vrijeme slanja odgovora, po satu poslužitelja
4. t_4^k – vrijeme primitka odgovora, po satu klijenta.

Oznake ('potencije') 'k' i 'p' u vremenima označavaju vremena izražena u klijentskim i poslužiteljskim satovima.

Prvo i zadnje vrijeme je očitano sa strane klijenta po njegovu satu, a drugo i treće na strani poslužitelja po njegovu satu. Ako pretpostavimo da satovi jednako precizno odbrojavaju u zadanom intervalu (osim što nisu usklađeni po apsolutnoj vrijednosti, jedna sekunda jednako traje u oba sustava), onda možemo izračunati:

- kašnjenje mreže (engl. *round trip delay*):

$$d = T_A - T_B = (t_4^k - t_1^k) - (t_3^p - t_2^p) \tag{8.3.}$$

- razliku u satovima (engl. *offset*):

$$c = t_B - t_A = (t_2^p + t_3^p)/2 - (t_1^k + t_4^k)/2 \tag{8.4.}$$

Naime, ako od proteklog vremena ($T_A = t_4^k - t_1^k$) oduzmemo vrijeme obrade zahtjeva na poslužitelju ($T_B = t_3^p - t_2^p$) ostaje vrijeme puta. Ako je trajanje puta paketa sa zahtjevom jednako trajanju puta paketa s odgovorom, što je pretpostavljeno, onda možemo zaključiti da bi se sredine intervala vremena na klijentskoj strani ($t_A = (t_1^k + t_4^k)/2$) i na poslužiteljskoj strani ($t_B = (t_2^p + t_3^p)/2$) poklopile kada bi satovi bili usklađeni. Ako satovi nisu usklađeni, razlika u sredinama tih intervala jest odstupanje u satovima. Da bi klijent uskladio svoj sat s poslužiteljskim satom, po primitku odgovora od poslužitelja on na svoj sat mora dodati c.

Slika 8.3. prikazuje primjer klijenta i poslužitelja s razlikom u vremenima. Vremena koja su okvirena se očitaju/izračunavaju korištenjem samo sata klijenta (t_1^k, t_4^k, T_A i t_A^k), odnosno poslužitelja (t_2^p, t_3^p, T_B i t_B^p).

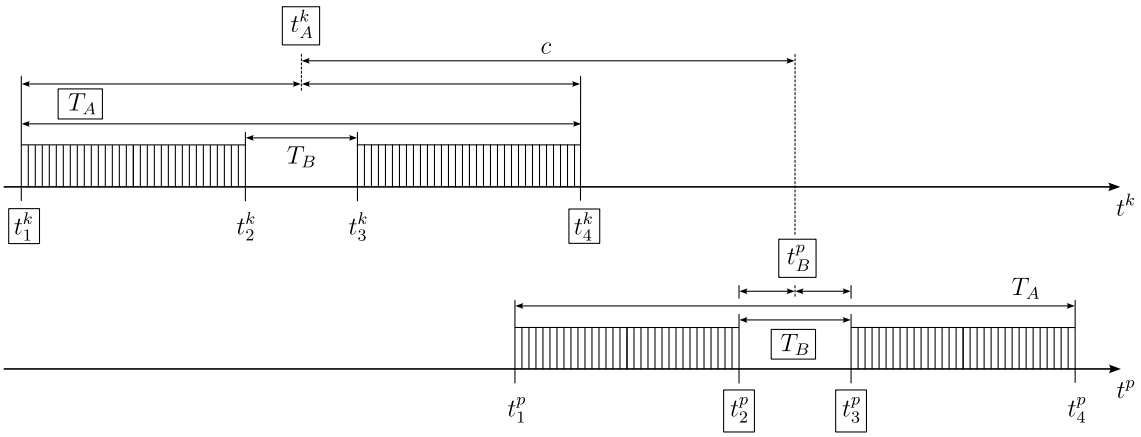

Slika 8.3. Primjer neusklađenih sustava

Primjer 8.2. Nesimetrična veza

Neka je slanje zahtjeva četverostruko sporije od primanja odgovora (puta paketa u tom smjeru), tada bi se t_A koji se koristi u prethodnom primjeru u formuli 8.4. za računanje razlike u satovima sada računao prema:

$$t_A = t_1^k + 4/5 \cdot d + T_B/2 \tag{8.5.}$$

Trajanje prijenosa dijeli se u omjeru 4:1 te je prvi dio 4/5 te vrijednosti, na što se još zbraja pola intervala T_B da bi došli do iste točke koja odgovara t_B kod poslužitelja. Navedeni primjer prikazuje slika 8.4.

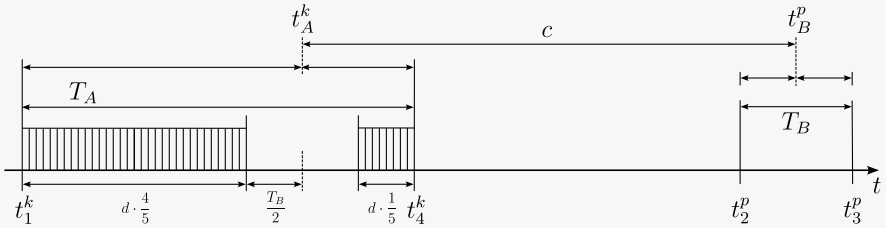

Slika 8.4.

$$d = T_A - T_B \;\Rightarrow\; t_A = t_1^k + d \cdot 4/5 + T_B/2 \;\Rightarrow\; c = t_B - t_A \tag{8.6.}$$

Pitanja za vježbu 8

1. Navesti slojeve protokolnog sloga Internet.
2. Koji su razlozi nepouzdanosti (loših vremenskih svojstava) mreže koja se temelji na Internetu i njegovim protokolima?
3. Zašto TCP nije dobar za primjenu u SRSV-ima? Zašto se umjesto njega preferira UDP i nad njime izgrađuju komunikacijski kanali (protokoli)?
4. Navesti moguće izvedbe spajanja računala u mrežu. Opisati svojstva pojedinih načina.
5. Koja se svojstva komunikacijskog sustava razmatraju pri analizi tih sustava? Koja od njih su osobito bitna za SRSV-e?
6. Opisati mogućnosti sabirnice CAN koje se koristi za izbjegavanje kolizije na zajedničkom mediju?
7. Što je to RTP/RTCP? Za što se koristi?
8. Na primjeru prikazati sinkronizaciju sata na čvoru klijenta sa čvorom poslužitelja.
9. U nekom sustavu čvor I pristupa čvoru J preko asimetrične veze: slanje poruka je pet puta sporije od primanja. Ako je lokalno vrijeme slanja poruke u čvoru I 10 te primanja odgovora 50, dok je vrijeme primanja poruke u čvoru J 30 i vrijeme slanja 40 (u lokalnom vremenu čvora J) odrediti vrijeme prijenosa podataka od čvora I do J i obratno te razlika među satovima ($t_\mathrm{I} = t_\mathrm{J} +$ razlika).
10. Satelit A treba uskladiti svoj sat sa satelitom B. Udaljenost među satelitima jest 300 000 km. Opisati postupak sinkronizacije i pokazati njegov rad na primjeru ako je u tom početnom trenutku sat na A imao vrijednost 13:13:13.111111 a sat na B 13:13:13.111222. Obrada poruka traje 0,0001 s.

9. Posebnosti izgradnja programske potpore za SRSV-e

Osim poznavanja postupaka/algoritama, pri samoj izradi programa (programiranju) treba uzeti u obzir i mogućnosti programskog jezika koji se koristi, svojstva alata s kojim se sustav izgrađuje, mogućnosti procjene ili mjerenja trajanja pojedinih dijelova programa na stvarnom sustavu.

9.1. Programski jezici

Svi se programski jezici mogu koristiti za izgradnju SRSV-a (u pravom okruženju, uz prikladan operacijski sustav i sklopovlje). Ipak, svaki od njih imaju svoje prednosti i nedostatke. Sa stanovišta SRSV-a bitno je jako dobro poznavati svojstva programskih jezika i načina njihova prevođenja ili interpretiranja. Također, vrlo je bitna podrška za vremenski usklađeno upravljanje koje omogućuje programski jezik ili njegova proširenja.

Najčešće korišteni jezik za izradu SRSV-a jest C zbog postojeće baze programa i programera. Ipak, i drugi se programski jezici mogu koristiti, počevši od uobičajenog izbora za obične programe, poput C++, C# i Java, ali i drugi, primjerice skriptni i slični jezici koji se interpretiraju (Perl, Python).

Osim programskih jezika opće namjene, za SRSV izgrađeni su dodatni programski jezici kao što je Ada.

9.1.1. Programski jezik C

Za programiranje na niskoj razini, gdje je potrebno upravljati mikroupravljačem (mikrokontrolerom) ili koristiti posebne sklopove, najprikladniji odabir jesu C i asembler. Vrlo pažljivom uporabom programi pisani u njima mogu biti i značajno učinkovitiji (brži). Ipak, s obzirom na to da su to jezici niske razine, izrada programske podrške može biti dugotrajnija nego korištenjem programskih jezika više razine i podložnija greškama u kôdu.

Programski jezik C je jedan od najstarijih te za njega ima vrlo mnogo proširenja (biblioteka), a neka od njih su i za podršku SRSV-u. U prethodnim poglavljima prikazana su neka sučelja koja nudi POSIX za programski jezik C. Slična sučelja i proširenja postoje i za neke druge programske jezike (npr. Real-Time za Javu).

U programskom jeziku C gotovo je sve dozvoljeno. Primjerice, svaki dio spremnika se jednostavno dohvaća i mijenja. Zato je C vrlo moćan, ali i potencijalno opasan zbog mogućih grešaka koje se lako previde, a teško otkriju.

9.1.2. Programski jezik Ada

Rad na osmišljavanju programskog jezika Ada započeo je krajem ’70-tih i početkom ’80-tih godina prošlog stoljeća kao projekt američkog ureda za obranu (DoD), ali se njegov razvoj i dalje nastavlja (Ada95, Ada2005, Ada2012). Ada je proširenje Pascala (i drugih) sa svrhom da bude jezik za korištenje u ugrađenim sustavima i SRSV-ima. Zato Ada ima ugrađene mehanizme u sam jezik koji značajno pomažu u takvim okolinama. Primjerice, tu spadaju:

- podrška za rad u stvarnom vremenu (u smislu upravljanja vremenom u zadacima)
- upravljanje dretvama (zadacima, *task* u Adi), od njihove sinkronizacije, komunikacije, ras-

poređivanja raznim strategijama (Ada ima vlastiti raspoređivač)

- podrška radu ulazno-izlaznih naprava.

Sljedeći primjer prikazuje neke mogućnosti Ade za upravljanje vremenom i dretvama. Program prikazuje rad dva zadatka `ping` i `pong` (uz glavni zadatak koji počinje u zadnjem bloku `begin /end`).

Isječak kôda 9.1. Primjer programa u Adi

```
with Ada.Text_IO, Ada.Integer_Text_IO;
use  Ada.Text_IO, Ada.Integer_Text_IO;

procedure ping_pong_primjer is

  task ping is
    entry pong_ping;
  end ping;

  task body ping is
  begin
    loop
      select
        delay 1.0;
        Put_line("ping");
      or
        accept pong_ping do
          Put_Line("ping");
        end pong_ping;
        delay 1.0;
        pong.ping_pong;
      end select;
    end loop;
  end ping;

  task pong is
    entry ping_pong;
  end pong;

  task body pong is
  begin
    loop
      accept ping_pong do
        Put_Line("pong");
      end ping_pong;
      ping.pong_ping;
    end loop;
  end pong;

begin
  delay 3.5;
  ping.pong_ping;
end ping_pong_primjer;
```

Podrška za vremensko usklađivanje i višedretvenost je ugrađena u programski jezik. Zadatak se definira tipom `task`, a svi definirani zadaci automatski se pokreću s glavnim zadatkom. Odgoda, sinkronizacija i reakcija na događaje dio su programskog jezika. Primjerice, zadatak `ping` kontrukcijom `select` s `delay` u jednoj grani i `accept` u drugoj, odgađa zadatak `ping` do jedne sekunde. Ako se unutar te sekunde ne pojavi zahtjev za sinkronizacijom na točki `pong_ping` odabire se prva grana `select`-a, tj. ispisuje se “ping”.

S obzirom na namijenjenu uporabu Ada ima vrlo strogu provjeru tipova podataka, kako pri-

likom prevođenja izvornog kôda tako i pri radu. Na primjer, ako je varijabla `x` definirana da prima vrijednosti između 5 i 10 tada pokušaj stavljanja neke druge vrijednosti neće biti moguće: ako prevoditelj može to ustanoviti javit će grešku pri prevođenju, ali će i u izvršnu inačicu programa ugraditi kôd koji dinamički otkriva pokušaj stavljanja vrijednost izvan dozvoljenog opsega te izazva iznimku (engl. *run-time checks*).

9.2. Prevoditelj

Programi u višim programskim jezicima (tu se uključuje i C) prevode se u instrukcije korištenjem prevoditelja (ili generatora kôda). Osim poznavanja korištenih programskih jezika, treba znati i kako se taj program prevodi te kako iskoristiti prevoditelj za izgradnju boljeg koda i pronalaženje mogućih grešaka.

Prevoditelj će prilikom rada prikazati greške u programu koje on može otkriti. Međutim, to su samo greške u sintaksi programska jezika. Logičke greške on ne može otkriti. Ipak, prevoditelji imaju mogućnosti odabira različite razine povratnih informacija preko takozvanih upozorenja (engl. *warnings*). Takva upozorenja mogu biti nebitna kao što je to npr. varijabla koja je definirana, ali nije korištena. Međutim, ponekad ona mogu biti pokazatelji da je nešto krivo ili bi moglo biti krivo. Primjerice, ako je upozorenje da je vrijednost varijable postavljena, ali se ne koristi, to može biti pokazatelj da možda nešto nedostaje – kôd u kojem se ta vrijednost koristi. Stoga je preporuka uključiti sve razine upozorenja koje prevoditelj može dati. Takva upozorenja je najbolje odmah i rješavati. U protivnom bi se pri prevođenju moglo pojaviti puno upozorenja od kojih su neka i bitna, a možda ih korisnik ne primijeti. Ako se svako takvo upozorenje rješava (otklanja izmjenama u kodu), tada bi svako novo upozorenje nastalo novim izmjenama koda odmah bilo vidljivo. Prevoditelj *gcc* ima mnoštvo zastavica za upravljanje razinama upozorenja. Primjerice, zastavicom `-Wall` aktiviraju se sve razine upozorenja, a zastavicom `-Werror` se s upozorenjima postupa kao i s greškama, prisiljavajući korisnika da ih ispravi.

Nadalje, pri prevođenju treba računati i na dodatne poslove koji su potrebni, a možda nisu izravno vidljivi iz kôda te optimizacije kôda radi brzine ili veličine programa i problemi koji zbog toga mogu nastati. Primjerice, pri pozivanju funkcije koristi se stog i to za prijenos parametara u funkciju, za pohranu konteksta te za lokalne varijable funkcije.

Pri pojavi prekida sprema se kontekst prekinute dretve. Pri povratku iz prekida obnavlja se kontekst. Ako se jezgrine funkcije pozivaju mehanizmom prekida, što je uobičajeno za obične operacijske sustave (ali ne uvijek u operacijskim sustavima za rad u stvarnom vremenu), onda su pohrana i obnavljanje konteksta sastavni dio takvog poziva. Ponekad ti kućanski poslovi mogu značajno narušiti učinkovitost sustava u odnosu na planirano, pogotovo ako se jezgrine funkcije vrlo često pozivaju, a čemu može biti uzrok presitna zrnatost podjele posla po zadacima (te zbog toga učestala sinkronizacija).

Brzina izvođenja programa kao i njegova veličina u najvećoj su mjeri definirani samim programom (programiranjem), tj. posljedica rada programera. Ipak, mogućnosti današnjih prevoditelja u optimiranju kôda ne treba podcijeniti. Uobičajeno je da prevoditelji imaju nekoliko razina optimiranja koji se uključuju ili isključuju pri prevođenju posebnim zastavicama. Primjerice, kada se koristi *gcc* tada zastavicom `-O` određujemo razinu optimiranja, od osnovne razine `-O1` do potpune optimizacije s `-O3`. Ili se optimiranje može provesti korištenjem kriterija manje veličine programa, zastavicom `-Os`. Razina `-O0` isključuje optimiranja.

Najveća razina optimiranja prevoditelja uključuje i pretragu za funkcijama koje će se ugraditi u kôd programa na sva mjesta gdje se pozivaju i time izbjeći dio kućanskih poslova. Ipak, tu su mogućnosti i znanje prevoditelja ograničena i uputa programera s određenim ključnim riječima, poput `inline` u tipu funkcije, mogu znatno ubrzati program (na uštrb njegove veličine). Za

razliku od funkcija, makroi (u C-u definirani direktivom `#define`) se uvijek ugrađuju na mjesto s kojeg se pozivaju.

Ponekad se iz raznih razloga (npr. simulacija, kratka odgoda) u kôd ugrađuju petlje koje nemaju nikakav utjecaj na sustav, osim odgode zbog obavljanja tih instrukcija. Zato prevoditelj pri optimiranju može zaključiti da je taj dio kôda suvišan i izbaciti ga. Ako je taj dio kôda ipak potreban (a vjerojatno jest), onda se treba osigurati da ga prevoditelj ipak ostavi. Postoji nekoliko načina za to. Jedan od njih je ubacivanje spremničke barijere (engl. *memory barrier*) u dio kôda koji želimo zadržati (npr. u C-u s `asm volatile ("": : : "memory");`).

Primjerice, ako želimo simulirati rad procesora izvođenjem neke petlje određeni broj puta (prethodno proračunat), tada u C-u možemo umjesto obične prazne petlje:

```
    for(i = 0; i < loops; i++)
        ;
```

koristiti petlju s barijerom:

```
    for(i = 0; i < loops; i++)
        asm volatile("":::"memory");
```

U višeprocesorskim sustavima može se pojaviti potreba za sinkronizaciju radnim čekanjem (engl. *spinlock*). Primjerice, dio kôda s kojim to ostvarujemo može izgledati:

```
    while (rq_cnt == 0)
        ;
```

Međutim, kada je varijabla u uvjetu obična, a tijelo petlje nije prazno već složeno, prevoditelj možda ne provjerava da li se ta varijabla može promijeniti i iz drugih dijelova koda, paralelno od strane drugih dretvi ili iz obrade signala ili prekidnih funkcija. Da se to ne dogodi, najbolje je varijablu posebno označiti ključnom riječi `volatile` kojom se prevoditelju naglašava da se dotična varijabla može promijeniti i izvan određene funkcije (čak i djelovanjem drugih elemenata sustava, ne samo procesora), te da ju ne zadržava u registru procesora, već se svaki put ponovno dohvaća iz spremnika.

9.3. Problemi s višedretvenošću

Načini raspoređivanja dretvi, sinkronizacije i komunikacije su već prikazani u prethodnim poglavljima. Zajedničke strukture podataka treba zaštititi od istovremenog korištenja prikladnim sinkronizacijskim mehanizmima. U prvom redu tu spadaju globalne varijable. Međutim, osim njih treba paziti i na statički deklarirane varijable u funkcijama (sa `static`). Problem se pojavljuje kada istu funkciju paralelno pozovu i izvode dvije ili više dretvi. Da bi riješili problem, dio koji koristi zajedničke podatke treba zaključati od istovremenog korištenja, ili svakoj dretvi dati svoje podatke, primjerice tako da ih šaljemo u funkciju.

Isječak kôda 9.2. Funkcija neprikladna za višedretveni rad

```
void neka_funkcija(neka_struktura)
{
    static int brojac = 0;  //statički alocirana varijabla
    brojac += nešto();      //ovu liniju koda treba zašititi
}
```

Sličnih problema ima u mnogim funkcijama, primjerice funkcija `rand` te jedno njeno "rješenje" u obliku `rand_r`. Prva nije sigurna (u nekim sustavima) za višedretvene sustave (engl. *thread unsafe, MT unsafe, not reentrant*) jer koristi globalnu varijablu za čuvanje međurezultata (sjeme,

engl. *seed*) potrebnog za izračun pseudo slučajnog broja. Druga funkcija, `rand_r`, očekuje da parametar koji joj se šalje bude taj međurezultat te je zato ona sigurna i za višedretveno korištenje (engl. *thread safe, MT safe*), pa i za istovremene pozive od raznih dretvi (engl. *reentrant function*).

Isječak kôda 9.3. Korištenje zasebne varijable za svaku dretvu

```
void neka_funkcija(neka_struktura, int *brojac)
{
    *brojac += nešto();
}
```

Isječak kôda 9.4. Zaštita od istovremenog korištenja sinkronizacijskim funkcijama

```
void neka_funkcija(neka_struktura)
{
    static int brojac = 0;  //statički alocirana varijabla
    static pthread_mutex_t KO = PTHREAD_MUTEX_INITIALIZER;
    int tmp;
    tmp = nešto();
    pthread_mutex_lock(&KO);
    brojac += tmp;
    pthread_mutex_unlock(&KO);
}
```

U arhitekturama koje dozvoljavaju nedjeljive operacije nad operandima u radnom spremniku, problem iz prethodnog primjera se može riješiti i efikasnije korištenjem takvih operacija. Primjer takvih instrukcija je "dohvati i zbroji" (engl. *fetch and add*) koja se pojavljuje u mnogim arhitekturama (npr. GCC-ov makro `__atomic_fetch_add`).

Isječak kôda 9.5. Korištenje atomarnih operacija

```
inline int dohvati_i_zbroji(int *a, int b)
{
    int c;
    c = __atomic_fetch_add(a, b, __ATOMIC_RELAXED);
    // atomarno: c = *a; *a = *a + b;
    return c;
}
```

Mnoga sučelja operacijskih sustava koriste i globalne varijable i statički rezervirane varijable u funkcijama. Zato ih se ne preporuča za višedretvene sustave. Primjerice, POSIX standard definira da sve funkcije, osim iznimaka [Thread-Safety], trebaju biti napisane da podržavaju višedretvene programe.

Problemi u višedretvenom radu mogu se pojaviti i ako se (neoprezno) koriste algoritmi sinkronizacije (npr. Lamportov algoritam). Naime, moderni procesori koriste izvođenje instrukcije "preko reda" (engl. *out of order*) što može izazvati probleme u nekim algoritmima ako se ne koriste posebne strukture podataka (npr. `atomic_int`) ili instrukcije prevoditelju.

9.4. Preciznost

U sustavima gdje je preciznost vrlo bitna treba uzeti u obzir svojstva različitih tipova podataka. Primjerice, u C-u postoje dvije osnovne skupine brojeva: cjelobrojni i podaci s pomičnom točkom (realni brojevi). Obje skupine imaju nekoliko tipova podataka, prikazanih tablicama 9.1. i 9.2.

Tablica 9.1. Uobičajene granice cjelobrojnih tipova podataka u C-u

oznaka tipa	broj bitova	raspon	raspon uz `unsigned`
`char`	8	$[-2^7; 2^7-1]$	$[0; 2^8-1]$
`short int`	16	$[-2^{15}; 2^{15}-1]$	$[0; 2^{16}-1]$
`int`	32	$[-2^{31}; 2^{31}-1]$	$[0; 2^{32}-1]$
`long int`	32 (64)	$[-2^{31}; 2^{31}-1]$	$[0; 2^{32}-1]$
`long long int`	64	$[-2^{63}; 2^{63}-1]$	$[0; 2^{64}-1]$

Tablica 9.2. Granice realnih tipova podataka u C-u (prema IEEE 754)

oznaka tipa	broj bitova	raspon (okvirno)	preciznost u znamenkama
`float`	32	$[10^{-38}; 10^{38}]$	7
`double`	64	$[10^{-308}; 10^{308}]$	16
`long double`	$64-128$	$[10^{-4932}; 10^{4932}]$	34

Tablice prikazuju raspone pojedinih tipova podataka. Pri odabiru tipa varijabli treba paziti da ne dođe do preljeva, tj. da se zbrajanjem ili oduzimanjem vrijednosti ne pređe preko najveće ili najmanje vrijednosti i time dobije krivi rezultat. Tip `long double` ima razna značenja u različitim okruženjima (prevoditeljima). Za neke je to isto kao i `double`, neki to proširuju na 80 bita jer je to podržano Intelovim procesorima (npr. GCC), a neki i više. U tablici je navedena specifikacija koja se u normi IEEE 754-2008 označava sa *binary128*.

Kada se koriste konstante, tj. brojevi u formulama (a ne samo varijable), uz rjeđe korištene tipove ne zaboraviti da uz sam broj treba dodati oznaku tipa (L, LL, UL). Inače će se pretpostaviti običan tip podataka i možda će se izgubiti željena preciznost (iako bi prevoditelj na to trebao upozoriti). Npr. broj `12345678901234LL` će se prepoznati kao `long long` tip, a broj `3.14e1000L` kao `long double`.

Kad se koriste realni brojevi tada treba posebno obratiti pozornost na preciznost. Tablica 9.2. prikazuje preciznost pojedinih tipova podataka u broju decimala – do kuda je broj zapisan u varijabli ispravan (koliko decimalnih znamenki). Često je i najosnovniji tip `float` zadovoljavajući. Kada to nije tako može se koristiti dvostruko precizniji `double`, odnosno još precizniji `long double`.

Osim preciznosti, treba pripaziti da se u matematičkim operacijama ne pojavljuju brojevi bitno različih veličina. Primjerice ako se zbroje: $1 + 10^{-100}$ dobit će se 1, bez obzira na tip, jer preciznost svih tipova nije tolika da pamti 100 decimala. Prethodni rezultat i ne mora nužno biti problem, većinom to i nije. Međutim, kada bi iduća operacija bila oduzimanje s jedinicom, u stvarnosti bi očekivali rezultat 10^{-100}, dok bi zapravo u računalu dobili 0. Broj 10^{-100} je zaista jako mali i moguće je da se on u nekim primjenama može poistovjetiti s nulom. Što ako to nije tako? Što ako su očekivane vrijednosti zaista u tom rangu (10^{-100})? Onda treba prilagoditi algoritam izračunavanja. Primjer 9.1. prikazuje takav pristup.

Primjer 9.1. Rješavanje kvadratne jednadžbe

Rješenja kvadratne jednadžbe zadane formulom:

$$a\,x^2 + b\,x + c = 0 \tag{9.1.}$$

se računaju prema:

$$x_{1,2} = \frac{-b \pm \sqrt{b^2 - 4\,a\,c}}{2\,a} \tag{9.2.}$$

Ako pretpostavimo da se zaista radi o kvadratnoj jednadžbi, tj. da je $a \neq 0$, te da su rješenja realna (korijen veći od nule), onda se svejedno može pojaviti problem s preciznošću. Ako je drugi dio ispod korijena značajno manji od prvog, tj. ako je:

$$b^2 \gg 4\,a\,c \tag{9.3.}$$

onda će se dobiti rješenja:

$$\begin{aligned} x_1 &\approx -b/a \\ x_2 &\approx 0 \end{aligned} \tag{9.4.}$$

Ako se želi precizniji broj za x_2 uz isti uvjet (9.3.), jer se očekuje da je on jako mali, onda se formula (9.2.) može transformirati prema (9.5.) u (9.6.).

$$\begin{aligned} x_2 &= \frac{-b + \sqrt{b^2 - 4\,a\,c}}{2\,a} \cdot \frac{-b - \sqrt{b^2 - 4\,a\,c}}{-b - \sqrt{b^2 - 4\,a\,c}} \\ x_2 &= \frac{b^2 - \left(b^2 - 4\,a\,c\right)}{2\,a \cdot \left(-b - \sqrt{b^2 - 4\,a\,c}\right)} = \frac{4\,a\,c}{2\,a \cdot \left(-b - \sqrt{b^2 - 4\,a\,c}\right)} \\ x_2 &= \frac{2\,c}{-b - \sqrt{b^2 - 4\,a\,c}} \approx \frac{2\,c}{-2\,b} \end{aligned} \tag{9.5.}$$

$$x_2 \approx -\frac{c}{b} \tag{9.6.}$$

Zadnja formula će dati precizniju vrijednost za x_2 kada vrijedi (9.3.).

U rijetkim slučajevima potrebna je značajno veća preciznost nego što ju nude osnovni tipovi podataka. Tada je potrebno ili samostalno izgraditi strukture i algoritme koji će raditi u većoj preciznosti ili za to koristiti gotove biblioteke. Jedna od takvih biblioteka jest *The GNU Multiple Precision Arithmetic Library* (http://gmplib.org/). Ipak, pri razmatranju korištenja takvih postupaka i biblioteka treba imati na umu da su operacije s podacima visoke preciznosti značajno sporije od uobičajenih!

U numeričkim postupcima integracije treba razmotriti stabilnost postupka, tj. provjeriti da li za dane prilike (npr. duljina koraka integracije) postupak konvergira.

U postupcima optimiranja nekim od heurističkih ili kombinatoričkih algoritama potrebno je osigurati izračun u dozvoljenom vremenu s obzirom na to da ti postupci mogu duže potrajati. Ponekad je bolje uzeti i lošije rješenje, ali koje je izračunato u zadanom ograničenom vremenu, nego dobiti najbolje rješenje, ali prekasno.

9.5. Predvidivost trajanja – složenost postupaka

SRSV-i moraju biti deterministički sustavi. Da bi to mogli biti potrebno je poznavati i trajanje svih operacija, u najboljem slučaju, prosječno te u najgorem slučaju. Ocjena trajanja pojedinog postupka ili operacije može se napraviti:

- ispitnim pokretanjem sustava ili samo jedne njegove komponente
- procjenom trajanja s obzirom na poznavanje postupka (u fazi projektiranja sustava).

Procjena treba ustanoviti kakve instrukcije procesor pokreće i koliko one traju. U današnjim sustavima u kojima prevladavaju RISC procesori (engl. *reduced instruction set computing*), nema prevelikih razlika između trajanja pojedinih instrukcija, kao nekada kada su operacije množenja, dijeljenja i složenije značajno duže trajale od zbrajanja, oduzimanja i logičkih operacija. Međutim, velike razlike mogu nastati zbog neučinkovitog korištenja priručnog spremnika procesora, ako se podaci ne koriste slijedno nego im se pristupa raštrkano. Ipak, pri procjeni se takvi problemi često razmatraju odvojeno, tj. zasebno se procjenjuje složenost postupka, primjerice u broju operacija ili broju instrukcija, te zasebno dodatna kašnjenja zbog raznih razloga, kao što je problem promašaja u priručnom spremniku, ili u postupku straničenja.

Složenost postupka se često izražava u notaciji veliko O. Složenost se izražava u dimenzijama problema. Primjerice, $O(n^2)$ kaže da će broj operacija u postupku koji koristi skup od n podataka biti proporcionalan s n^2, odnosno preciznije, da je gornja ograda broja operacija proporcionalna s n^2. Ako n raste, broj operacija raste kvadratno. Zato se i za notaciju O kaže da označava mjeru rasta složenosti postupka. Tablica 9.3. prikazuje uobičajene vrijednosti za složenost algoritama.

Tablica 9.3. Primjeri složenosti postupaka

notacija	naziv složenosti	primjeri postupaka takve složenosti
$O(1)$	konstantna	pristup podacima iz tablice; izračun vrijednosti bez iteracija ili uvijek s istim brojem iteracija
$O(\log n)$	logaritamska	binarno pretraživanje uređenog polja; pretraživanje binarnog stabla
$O(n)$	linearna	slijedno pretraživanje polja
$O(n \log n)$	linearno log.	FFT, *quick-sort*
$O(n^2)$	kvadratna	množenje dva vektora, *buble-sort*
$O(n^c),\ c > 1$	polinomska	množenje matrica (i višedimenzionalnih podataka)
$O(c^n)$	eksponencijalna	pretraga n-dimenzionalnog neuređenog prostora
$O(n!)$	faktorijelna	traženje optimalnog rješenja kombinatoričkog problema potpunom pretragom skupa mogućih rješenja, primjerice problem trgovačkog putnika

Što je složenost veća postupak će dulje potrajati, ali i razlika u trajanju istog postupka nad različitim podacima u različitim trenucima će biti veća – povećava se problem predvidivosti trajanja postupaka. Ako složenost postaje problem, onda ju treba pokušati riješiti na razne načine, ili odabirom drugog postupka manje složenosti, makar i manje kvalitete rješenja, ili optimiranjem postojećeg.

Jedan od često primjenjivanih postupaka smanjenja složenosti proračuna jest korištenjem tablica. Umjesto da se vrijednosti izračunavaju tijekom rada korištenjem složenih postupaka, one se proračunaju prije pokretanja (engl. *offline*), kada vrijeme nije kritično i to za sve moguće vrijednosti ulaza. Pri radu za svaku traženu vrijednost uzima se već proračunata vrijednost iz tablice. Nažalost, takvo pojednostavljenje nije uvijek moguće, a i kada jest tada može znatno povećati zahtjeve na spremnički prostor računala za pohranu tablice, tj. složenost se iz vremenske domene rješava ili smanjuje povećanjem složenosti u prostornoj domeni.

Primjer 9.2. Složenost zbrajanja matrica

Složenost zbrajanja matrica (prema sljedećem algoritmu) proporcionalna je umnošku dimenzija matrica: $broj\_redaka \times broj\_stupaca$.

```
zbroji_matrice(a, b, c) // c = a + b
    za i = 0 do a.broj_redaka radi
        za j = 0 do a.broj_stupaca radi
            c[i][j] = a[i][j] + b[i][j];
```

Povećanjem samo jedne dimenzije matrica (npr. samo broj redaka) složenost se linearno povećava. Povećanjem obiju dimenzija složenost raste kvadratno. Primjerice, ako su matrice kvadratne s n redaka i n stupaca, složenost zbrajanja jest $O(n^2)$.

Primjer 9.3. Složenost umetanja u uređenu listu

Umetanje u listu jest linearne složenosti $O(n)$.

```
ubaci(lista, novi_objekt) # uređenje je od najmanjeg prema najvećem
    ako je lista.prvi == null ILI lista.prvi > novi_objekt tada
        novi_objekt.iduci = lista.prvi
        lista.prvi = novi_objekt
    inače
        i = lista.prvi
        dok je i.iduci != null I i.iduci < novi_objekt radi
            i = i.iduci
        novi_objekt.iduci = i.iduci
        i.iduci = novi_objekt
```

U prosjeku će se pretraživati pola elemenata liste. Ipak, najgori slučaj će biti kada novi element mora na kraj liste (n iteracija).

9.6. Višeprocesorski i višejezgreni sustavi

Noviji sustavi često su opremljeni s jednim procesorom koji ima više procesnih jedinki (višestruki, višejezgreni procesor, engl. *multicore*). Operacijski sustavi uglavnom ne rade veliku razliku između jedne jezgre višejezgrenog procesora od zasebnog, običnog procesora u višeprocesorskom sustavu. Kod oba sustava, i višeprocesorskog i sustava s višejezgrenim procesorom ili više njih i dalje treba paziti na korištenje dijeljenih sredstava.

Međutim, s obzirom na to da procesne jedinke višejezgrenog procesora dijele zajedničku sabirnicu prema glavnom spremniku i ostalim sklopovima, rad jedne dretve na jednoj procesorskoj jedinki (jezgri) može utjecati na druge. Nadalje, te dretve dijele i priručni spremnik tog pro-

cesora (označavanog s L2 i L3). Naime, iako se dvije dretve različita prioriteta mogu izvoditi paralelno na dvije različite procesorske jedinke, zbog intenzivnih promašaja (zahtjeva za podacima koji nisu u priručnom spremniku procesora) kojima uzrok može biti dretva manjeg prioriteta, prioritetnija dretva može biti manje ili više usporena u svom radu. Dretva manjeg prioriteta će koristiti (zbog promašaja) veći dio priručnog spremnika pa će manji dio ostati za prioritetniju koja će zbog toga i sama više promašivati, tj. usporit će se i njen rad. Rješenje ili ublažavanje tog problema zahtjeva nadogradnju raspoređivača dretvi koji treba uzeti u obzir prioritete te ponekad zaustaviti dretvu manjeg prioritetna na jednoj jezgri kada ustanovljava porast broj promašaja koje ona izaziva, ili takvu dretvu premjestiti na drugi procesor. Takvi raspoređivači su tek u razvojnoj i ispitnoj fazi, ali je za očekivati da će se u bliskoj budućnosti pojaviti u operacijskim sustavima za rad u stvarnom vremenu (a možda i ostalima).

9.7. Korištenje ispitnih uzoraka

Ispitivanje ispravnosti je jedna od najvažnijih aktivnosti u procesu izgradnje programske potpore (a i sklopovske). Ispitivanje se treba provoditi tijekom cijele faze izrade, ali je onaj najopsežniji dio ipak na kraju kad je programska potpora već izgrađena. Za taj zadnji dio potrebni su ispitni uzorci koji će se iskoristiti pri ispitivanju. Ispitni uzorci često predstavljaju scenarije uporabe i mogu biti pokretač izgradnje, nešto oko čega će se oblikovati arhitektura sustava i komponente. Opća je preporuka da se već u početku, paralelno s izradom specifikacije sustava definiraju ispitni uzorci. Oni mogu poslužiti i radi provjere specifikacije, je li definirano zaista ono što sustav treba raditi.

Pitanje je kako definirati ispitne uzorke? Više o toj problematici može se pronaći drugdje (u drugim predmetima ili materijalima [Bogunović, 2012]). Sažeto se može reći da ti ispitni uzorci trebaju pokrivati sve distinktivne dijelove domene, da ih ne smije biti previše (jer će ispitivanje jako dugo trajati), treba ih provjeriti s naručiteljem (i pravim korisnicima tog sustava), treba ih snimiti u domeni korištenja (od strane razvojnog tima, ne samo od strane naručitelja).

S obzirom na to da su SRSV često kritični sustavi, ispitivanje i programske komponente mora biti temeljito, tj. značajno opsežnije od ispitivanja koje se provodi kod ostalih sustava.

9.8. Provjera povratnih vrijednosti funkcija

Pri učenju programiranja i demonstraciji programa radi jednostavnijeg prikaza se najčešće pretpostavi da će uobičajene funkcije ispravno obaviti svoje operacije (npr. `printf`, `sleep`). Međutim, radi veće ispravnosti potrebno je provjeriti svaku povratnu vrijednost svake funkcije koje vraćaju vrijednost. U slučaju greške, kada funkcija vrati grešku (najčešće vrijednost -1) može se uvidom u oznaku greške (engl. *error number, errno*) doznati i više informacija o razlogu greške i dalje postupiti odgovarajuće.

U ovoj knjizi se vrlo često pretpostavilo da će funkcije raditi ispravno i nije se provjeravala povratna vrijednost mnogih funkcija. Korištenjem svih provjera kôd postaje veći i malo manje čitljiv te je iz tog razloga niz provjera izostavljen, ali se to nikako ne preporuča u stvarnim sustavima, pogotovo ugrađenim, gdje mnoge stvari mogu postati problem te čak i "najobičnije" funkcije, kao što su `printf`, `read`, `write`, `sleep` i slične ne naprave svoje i jave grešku.

Primjer razloga neuspjeha funkcija jest primitak signala dok je dretva bila blokirana na nekoj jezgrinoj funkciji (npr. sinkronizacijskom ili komunikacijskom mehanizmu, ili čekanje na dovršetak ulazno-izlazne operacije). Signal prekida to čekanje – najprije se signal obrađuje a onda najčešće takva funkcija vraća grešku (-1 kao povratnu vrijednost uz oznaku greške postavljenu na EINTR). Stoga je vrlo bitno provjeriti povratnu vrijednost takvih funkcija.

9.9. Oporavak od pogreške

Složenost računalnih sustava uzrokuje greške i u vrlo opsežno ispitanim sustavima. Što je sustav bolje ispitan manja je vjerojatnost pojave greške tijekom rada. Međutim, što napraviti kada se greška ipak dogodi?

U poglavlju 6.2. prikazan je jedan postupak oporavka od pogreške koja se prikazuje kao zastoj u radu kritičnih operacija, kada se zbog toga aktivira nadzorni alarm. Naime, zbog neke greške u jednom dijelu programa, upravljački program ne dolazi do kritičnog dijela u kojem se nadzorni alarm resetira. Stoga je jedno od rješenja ponovno pokrenuti sustav s nadom da neće opet doći u takvo stanje.

Grešku je ponekad moguće otkriti dodavanjem kôda koji služi isključivo za provjeru ispravnog rada i stanja sustava.

Ponekad je kôd koji ispituje ispravno stanje sustava (npr. provjeru varijabli, argumenata funkcije, povratnih vrijednosti i slično) aktivan samo pri ispitivanju rada, ali ne i kasnije tijekom stvarnog korištenja sustava (nakon ispitivanja taj se kôd isključuje radi ostvarivanje veće učinkovitosti). Primjer ovakva ispitivanja jest korištenje makroa `assert`:

```
assert(nešto_što_bi_trebalo_biti_istina);
```

Ako se navedeni uvjet ne izračuna u istinu, program se zaustavlja (pozivom `abort`).

Zaustavljanje uz ispis poruke o grešci može imati smisla u sustavima koja su nadzirana od strane čovjeka ili su pristupačna. Međutim, ako su takvi sustavi nedostupni (udaljeni) navedeni pristup će ih jednostavno zaustaviti. Možda i takav postupak ima smisla u neki sustavima. U drugim sustavima će biti bolje da je sustav i dalje aktivan, da se pokuša nekako izvući iz stanja kvara.

Operacije otkrivanje grešaka i akcija na njih trebaju biti ugrađeni u sam kôd. Sljedeći primjer kôda pokušava otkriti grešku u sustavu i otkloniti ju.

Isječak kôda 9.6. Ugrađeni postupak oporavka od pogreške

```
...
if (temp < Tmin)
{
    log(WARN, "Temperatura manja od očekivane!");

    //očitaj ponovo, možda je bio problem u senzoru
    temp = TEMPERATURA(ocitaj_senzor(ulaz_55));
    if (temp < Tmin)
    {
        //je li grijač upaljen?
        if (ocitaj_senzor(ulaz_22) & GRIJAC)
        {
            //grijač upaljen, ali ne grije?
            log(ERROR, "Grijač 22 ne grije, resetiram sustav!");
            reset();
        }
        else {
            postavi_senzor(ulaz_22, GRIJAC);
            goto pricekaj_radno_stanje;
        }
    }
}
...
```

U prethodnome primjeru se sustav resetira tek ako ne postoji operacija koja bi iz tog stanja

dovela sustav u normalno stanje (brže od reseta). Ako ne postoji mogućnost da se sustav izbavi iz uočenog problema (npr. ako resetom nema nade da će grijač ipak proraditi), onda je jedino logično zaustaviti sustav (primjerice, umjesto `reset` staviti `abort` ili slično).

Ponekad je problem u nedostatku sredstava sustava. Naime, ugradbeni sustavi često imaju ograničenu veličinu radnog spremnika koji može postati usko grlo. Dinamička dodjela spremnika koja s jedne strane omogućava fleksibilnost u njegovu korištenju (veću učinkovitost korištenja spremnika), s druge strane može biti i problem kada slobodnog spremnika ponestane. Primjer u nastavku prikazuje jedno moguće upravljanje u takvim slučajevima.

Isječak kôda 9.7. Postupanje u slučaju nedostatnih sredstava sustava

```
while (posluzivanje_traje)
{
    zahtjev = dohvati_sljedeci_zahtjev(...);

    while (1) {
        stanje_obrade = malloc(sizeof(stanje_obrade));

        if (stanje_obrade) {
            //obrada zahtjeva
            ...
            break;
        }
        else {
            /* nema memorije ! */

            #ifdef KAD_NEMA_MEMORIJE__ODBACI_ZAHTJEVE
            /* 1. pristup: odbacuj zahtjeve */
            log(WARN, "Nema memorije za nove zahtjeve!");
            odbaci_zahtjev(zahtjev);
            break;
            #else
            /* 2. pristup: probati kratko pričekati pa ponoviti */
            nanosleep(kratko);
            continue;
            #endif
        }
    }
}
```

U SRSV-ima bi svakako trebalo uočiti moguće probleme i za njih ugraditi prikladan postupak oporavka od pogreške.

Pitanja za vježbu 9

1. Usporediti programske jezike C i Adu u kontekstu korištenja za SRSV.
2. Koja svojstva prevoditelja je moguće ili potrebno koristiti pri izgradnji programske potpore za SRSV-e?
3. Kada ugrađivati funkcije na mjesto poziva (definirati ih sa inline), a kada ne?
4. Čemu služi oznaka `volatile` pri definiranju varijabli? Koje probleme takva definicija rješava?

5. Za kakve funkcije kažemo da nisu prikladne za višedretveno okruženje?
6. Koje su granice zapisa cijelih tipova podataka te koja je preciznost realnih brojeva?
7. Na što je sve potrebno paziti pri korištenju višeprocesorskih i višejezgrinih sustava (kod raspoređivanja dretvi) u SRSV okruženju?
8. Kako se ponekad može smanjiti vremenska složenost postupka?
9. Što je to prostorna složenost?
10. Kako ispitni uzorci mogu utjecati na razvoj programske potpore?
11. Za zadani odsječak koda navesti nedostatke (u kontekstu korištenja u SRSV-ima).

```
printf("Unesi parametar A (5-10):");
scanf("%d", &A);
a = obrada (A);
if ( a > 5 )
  exit(-1);
else
  posalji(A, a);
```

12. Za dodjelu jedinstvenih identifikacijskih brojeva koristi se funkcija:
`int id (){ static int broj = 0; return broj++; }`.
Koje nedostatke ima navedena funkcija?
13. Navesti nedostatke navedena koda (u raznim "okruženjima") i mogućnosti za njihovo rješavanje.

```
int op ( ... ) {
    static int brojilo = 0;
    ...  /* neka operacija koja ne koristi varijablu brojilo */
    brojilo = brojilo + 1;
    return brojilo;
}
```

14. Odrediti složenost idućeg algoritma u O (veliko O) notaciji (`funkcija1` je linearne složenosti – $O(N)$).

```
    for ( i = 0; i < N; i++ )
        for ( j = i + 1; j < N; j++ )
            A[i][j] = funkcija ( i, j, N );
```

15. Popraviti sljedeću funkciju tako da općenito bude maksimalno moguće precizna uz zadane tipove podataka (bez mijenjanja tipova).

```
double funkcija2 ( double a, double b )
{
    double c;
    c = 1 - a / 1e50;
    if ( b > 0 )
        c = b * (c - 1);
    return c;
}
```

16. Neka se `x` i `y` računaju prema:

```
x = a - b*c;
y = d - x;
```

Koji problemi preciznosti mogu nastati izvođenjem programa, ako su sve varijable:

a) cjelobrojne

b) realne?

17. Između očitanja neke ulazne naprave treba proći između 20 i 50 sabirničkih ciklusa. Kako to ostvariti ako se može programirati u asembleru, te kako ako se mora koristiti C?

10. Operacijski sustavi

10.1. Uloga operacijskih sustava

Operacijski sustav je skup osnovnih programa koji se nalaze između korisnika računala, tj. programa i sklopovlja. Njegova je zadaća da programima pruži prikladnu okolinu za učinkovito korištenje računalnog sklopovlja, za suradnju na obavljanju zajedničkih zadataka i slično. U prethodnim poglavljima koristila se pretpostavka da operacijski sustav postoji i da ne unosi dodatne probleme u sustav. U ovom se poglavlju razmatraju neki detalji operacijskih sustava koji mogu utjecati na ukupna svojstva sustava, pogotovo ako ih se ne uzme u obzir pri projektiranju.

Slika 10.1. prikazuje uobičajeno mjesto operacijskog sustava u računalnom sustavu.

Slika 10.1. Slojevi računalnog sustava

Operacijski sustav je najkritičniji dio programskog okruženja nekog računalnog sustava te ga kao takvog smišljaju, izgrađuju i mijenjaju iskusni stručnjaci s ovog područja. Njegova korisnost mjerljiva je njegovim mogućnostima i brzini rada.

Različiti računalni sustavi postavljaju vlastite zahtjeve na programsko okruženje. Operacijski sustav osobnog računala, namijenjen mnoštvu aktivnosti kao što su uredski programi, pregledavanje i stvaranje multimedijalnih sadržaja te računalne igre, bitno se razlikuje od onog koje upravlja nekim proizvodnim procesom.

Većina funkcija koje operacijski sustavi danas imaju potiče od prvih operacijskih sustava razvijenih na poslužiteljskim računalima. Ti su prvi sustavi postavili temelje gotovo svim sustavima koje danas koristimo, bilo na osobnom računalu u uredu ili kući, ili poslužiteljima. Ipak, u području SRSV-a i ugrađenih računala uporaba operacijskih sustava znatno je manja. Neki ugrađeni sustavi toliko su jednostavni da nemaju potrebe korištenja operacijskog sustava već je dovoljan upravljački program. Kada se operacijski sustavi koriste u ovim okruženjima tada su ti operacijski sustavi znatno drukčijih svojstava.

Načela rada operacijskih sustava, osnovni koncepti i slično opširnije su opisani u literaturi, kao što je [Budin, 2011] i [Silberschatz, 2002].U nastavku slijedi kraći opis nekih dijelova OS-a koji su posebno odgovorni za svojstva bitna za SRSV-e.

Osnovni dijelovi operacijskog sustava (podsustavi) su:

1. upravljanje vanjskim jedinicama

2. upravljanje spremničkim prostorom
3. upravljanje vremenom
4. upravljanje dretvama/procesima
5. mehanizmi komunikacije i sinkronizacije
6. datotečni podsustav
7. mrežni podsustav.

Svojstva nekih od podsustava (3., 4., 5. i 7.) su već predstavljena u okviru problematike raspoređivanja, sinkronizacije, komunikacije i upravljanja vremenom (poglavlja 4. – 7.).

Upravljanje vanjskim jedinicama i spremničkim prostorom je vrlo bitno za operacijske sustave za rad u stvarnom vremenu jer to može znatno utjecati na način upravljanja i svojstva takvih sustava. Stoga su ta upravljanja dodatno opisana u nastavku.

10.1.1. Upravljanje vanjskim jedinicama

Upravljanje vanjskim jedinicama obavlja se preko sklopova preko kojih su vanjske jedinice spojene. Npr. USB naprava spojena je na računalo na USB priključak koji je upravljan USB upravljačem (kontrolerom) – programi i OS komuniciraju s tim upravljačem da bi primili i poslali podatke prema napravi. U nastavku se pod "vanjskom jedinicom" ili "napravom" zapravo podrazumijeva takav upravljač.

Upravljanje vanjskim jedinicama u sustavima koji koriste operacijski sustav obavlja se preko njega. U sustavima koji nemaju OS, upravljanje se može izvesti izravno iz programa.

Svaka vanjska jedinica ima svoje posebnosti. Da bi se olakšalo izgradnju operacijskih sustava, složenost upravljanja napravama se izdvaja u posebne dijelove koje nazivamo "upravljačkim programima naprava" ili samo "upravljački program" kad smo u kontekstu operacijskih sustava (engl. *device driver*).

Upravljanje vanjskim jedinicama, tj. ulazno-izlaznim napravama se može obavljati na tri načina:

1. upravljanje programskom petljom
2. korištenjem prekida
3. korištenjem sklopova za izravni pristup spremniku.

Upravljanje programskom petljom izvodi se samo za najjednostavnije naprave koje nemaju upravljačke sklopove. Upravljački program mora sve sam napraviti – provjeravati stanje naprave (treba li nešto napraviti s napravom), slati naredbe i podatke u napravu, čitati podatke i stanja naprave. Najveći problem jest ustanoviti kada se nešto dogodilo, jer naprava neće sama zatražiti akciju. Upravljački program za takvu napravu periodički provjerava stanje naprave i pokreće akcije kada se dogode promjene. Ako sustav ne može nastaviti s radom dok ne dobije podatke te naprave, mora se korisitit mehanizam radnog čekanja, tj. u petlji dohvaćati status naprave dok se on ne promijeni u željeni.

S druge strane, UI naprave sa sklopovima s izravnim pristupom spremniku se koriste za prijenos veće količine podataka od vanjske naprave ili prema njoj, a ne izravno za upravljanje te se zato ovdje neće posebno razmatrati.

Prekidi su najčešće korišten mehanizam za upravljanje vanjskim jedinicama. Oni omogućavaju da naprave šalju prekidni signal u trenucima kada se dogodi promjena na samim napravama. Operacijski sustav na prekidne signale poziva odgovarajuće funkcije koje će obraditi te doga-

đaje. Reakcija će stoga biti vrlo brza. Izuzetak su zahtjevi koji se pojave za vrijeme prihvata/obrade prethodnih zahtjeva. Pri prihvatu zahtjeva za prekid prvo se obavljaju kućanski poslovi koje se ne smije prekidati, što uključuje spremanja konteksta trenutno prekinute dretve i otkrivanja uzroka prekida. Nadalje, sama obrada prekida može biti kritična operacija koju se ponekad ne smije prekidati te svi zahtjevi pristigli u to vrijeme će čekati kraj te obrade.

S obzirom na to da je za SRSV-e vrlo bitno promptno odgovoriti na zahtjev iz okoline, način prihvata i obrade prekida treba prilagoditi da zadovoljavaju vremenska ograničenja koja su postavljena prema reakcijama na vanjske događaje. Kada bi se neka obrada prekida izvodila sa zabranjenim prekidanjem i potrajala malo duže, to bi onemogućilo prihvat drugog prekida i reakciju na njega. Stoga se prekidni podsustav treba ostvariti da razlikuje takve obrade, odnosno da omogući da se najkritičnijim elementi upravljanog sustava posveti najviše pažnje, tj. da se vrlo brzo reagira na njihove zahtjeve.

Uobičajeni pristupi pri oblikovanju prekidnog podsustava su:

1. obrađivati prekide redom prispijeća
2. obrađivati prekide prema prioritetu te
3. obrade prekida podijeliti na dva dijela: hitni dio i manje hitni dio.

Obrada prekida redom prispijeća uz zadržavanje svih prekidnih zahtjeva dok se prethodni ne obrade je najjednostavniji i najčešće korišteni mehanizam. Da bi on bio svrsishodan neophodno je da sve obrade prekida traju vrlo kratko kako bi eventualno pristigli novi zahtjevi za prekid čekali jako malo. Ako je to za neku primjenu moguće napraviti onda je to pravo rješenje.

Obrađivanje prekida prema prioritetima bi trebalo biti najbolje rješenje. Ali ono, kao prvo, zahtijeva podršku sklopa za prihvat prekida koji mora omogućiti prekidanje manje prioritetnih obrada s prioritetnijima. Drugi problem mogu biti obrade koje se ako su započete ne smiju prekidati (bez obzira na prioritete novih zahtjeva). Također, treba uzeti u obzir da kućanski poslovi iako traju kratko, i ispod mikrosekunde na bržim sustavima, nisu zanemarivi ako se vrlo često izvode. Na svaki prekid se poziva prekidna procedura koja mora utvrditi uzrok prekida, oblikovati zahtjev za obradu te ga postaviti u red. Česti prekidi stoga mogu prekidati započetu obradu manjeg prioriteta koja zbog toga možda neće stići obaviti sve operacije do svog krajnjeg trenutka završetka.

Mogućnost podjele obrade u dva dijela kombinira prethodna dva pristupa: prekidi čija obrada traje kratko se izvode odmah, dok se duži prekidi dijele na hitni dio koji se odmah izvede te manje hitan dio koji se može izvesti i s većim odmakom. Kada za obradu prekida treba više vremena tada se u hitnom dijelu prikupe osnovni podaci potrebni za obradu u jedan zahtjev (npr. koja naprava, parametri, koju funkciju treba pozvati) koji se onda stavlja u listu zahtjeva. Sam se zahtjev obrađuje naknadno prema prioritetu u odnosu na druge zahtjeve u listi i to s dozvoljenim prekidanjem. Na taj način se može dozvoliti da obrada i dulje traje, a da ipak ne utječe na prekide koji traže hitnu obradu.

Operacijski sustavi za SRSV uglavnom omogućavaju samo osnovni način obrade prekida – prema redu prispijeća, jer se podrazumijeva da obrade prekida trebaju trajati vrlo kratko. Ipak, neki od takvih sustava omogućavaju da sama obrada ipak bude prekidiva drugim prioritetnijim zahtjevima, te na ovaj način omogućavaju obradu prekida prema prioritetu (koji je pridijeljen napravama).

Podjela obrade prekida na dva dijela podržana je i u operacijskim sustavima koji nisu predviđeni za rad u stvarnom vremenu. Primjerice, na sustavima zasnovanim na Win32 jezgri za hitan dio obrade prekida koristi se termin prekidna rutina (engl. *interrupt service routine*), a za manje hitan dio prekidna dretva (engl. *interrupt service thread*). Ekvivalentni termini za sus-

tave temeljenje na Linux jezgri su gornja polovica (engl. *top half*) za hitan dio obrade, te donja polovica (engl. *bottom half*) za manje hitan dio.

Operacijski sustavi nude mehanizme, ali je odluka arhitekta sustava kako će ih iskoristiti u određenim okolinama – hoće li sve obrade oblikovati da budu kratke, ili će obrade dijeliti na dva dijela, ili će uz sklopovsku potporu obrade prekidati priroitetnijim zahtjevima.

U funkcijama za obradu prekida treba paziti koje se funkcije koriste. Nije poželjno ili čak i moguće u njima koristiti funkcije koje mogu blokirati. Npr. poziv funkcije *ČekajSemafor* se ne bi smio koristiti u obradi prekida, dok poziv *PostaviSemafor* se smije – on neće blokirati izvođenje obrade.

10.1.2. Upravljanje spremničkim prostorom

Upravljanje spremničkim prostorom koristi algoritme koji odlučuju u koje dijelove spremnika učitati instrukcije, podatke, gdje smjestiti stog, gomilu, kako zaštititi jednu dretvu od druge, kako zaštititi operacijski sustav i slično. Najjednostavnije metode imaju najviše nedostataka, ali ne traže dodatne složene sklopove, dok složenije metode nude više, ali traže i sklopovsku potporu. Upravljanje spremnikom će stoga ovisiti o namjeni sustava (jednostavni ili složeniji) i o dostupnoj sklopovskoj potpori.

Osnovni načini upravljanja spremnikom su:

1. statičko upravljanje
2. dinamičko upravljanje
3. straničenje.

Sva tri načina imaju mogućnosti korištenja pomoćnog spremnika za privremenu pohranu procesa koji trenutno ne stanu u radni spremnik. Međutim, u kontekstu SRSV-a, korištenje pomoćnih spremnika je problematično s obzirom na to da to može uzrokovati značajne odgode u izvođenju tih programa zbog dohvata potrebnih podataka s pomoćnog spremnika (što se može mjeriti u desecima milisekundi). Ako se ipak koriste pomoćni spremnici treba biti vrlo oprezan što u njih postaviti. Najbolje bi bilo kada bismo na njih spremali samo nekritične programe, one koji ne upravljaju bitnim dijelovima sustava.

Kod statičkog upravljanja spremnik se podijeli u nekoliko segmenata u koji se smještaju različiti programi pripremljeni za te segmente (adrese koje se koriste u programima su pripremljene za te segmente). Odlike statičkog upravljanja su u njegovoj primjenjivosti i na najjednostavnijim procesorima, on ne traži nikakvu sklopovsku potporu za upravljanje spremnikom. Nedostaci su u fragmentaciji, nepostojanju zaštite, potrebe za prilagođavanjem programa za pojedine segmente, neučinkovitosti u korištenju spremnika.

Za ostvarenje dinamičkog upravljanja potrebna je sklopovska potpora u obliku jednog registra i jednog zbrajala. Korištenjem samo tih dviju povezanih komponenti omogućava se da programi ostaju u logičkim adresama, može ih se učitati bilo gdje u spremnik – spremnik ne treba unaprijed podijeliti na segmente. Dodatkom dva komparatora može se ostvariti i zaštita spremnika, tj. ograničiti pristup spremniku na dodijeljeni segment. Nedostaci uključuju fragmentaciju i neučinkovitost u korištenju spremnika.

Straničenje dijeli adresni prostor procesa na stranice, spremnik na okvire dimenzija stranice te uz pomoć sklopovlja omogućava da se stranice procesa nalaze u bilo kojim okvirima, bilo kojim redoslijedom. Prednost u ovoj, na prvi pogled usitnjenoj slici spremnika jest u fleksibilnosti. Pojedini proces pri svom pokretanju može koristiti jedan skup okvira, a kasnije tražiti još, otpuštati one koje više ne koristi i slično (kod statičkog i dinamičkog upravljanja, sav se adresni

prostor za proces trebao odmah zauzeti pri pokretanju procesa). Nadalje, kao i kod dinamičkog upravljanja, kod straničenja proces ostaje u logičkim adresama dok se pretvorba adresa obavlja sklopovljem. Straničenje zahtjeva značajno složenije sklopovlje i strukturu podataka – to je njegov najveći nedostatak za primjenu u ugrađenim sustavima. S obzirom na to da sklopovlje adrese prevodi preko tablica (koje treba pripremati operacijski sustav) zaštita između procesa i procesa, procesa i jezgre je lako ostvariva. Nadalje, tablice se mogu tako izgraditi da omogućuju dijeljenje adresnog prostora između dva procesa, omogućujući iznimno brzu komunikaciju ta dva procesa bez korištenja posrednika (operacijskog sustava).

Od tri navedena načina upravljanja spremnikom, straničenje je najbolje po svojstvima, ali zbog potrebe složenog sklopa nije primjenjivo na svim sustavima – na jednostavnijim upravljačkim računalima, osobito ugrađenim.

Radi rješavanja problema korištenja pomoćnog spremnika, kritični programi mogu zatražiti stalni smještaj svojih elemenata u radnom spremniku. Primjerice korištenjem poziva `mlock` i `mlockall`. Ako programi dinamički traže dodatni spremnički prostor (primjerice s `malloc`) tada je dodatno potrebno osigurati da i taj naknadno traženi prostor ne bi bio dodijeljen na pomoćnom spremniku. Jedna od mogućnosti za to jest na početku programa rezervirati dio spremničkog prostora koji će biti dostatan i u najzahtjevnijim trenucima. Potom zaključati sve stranice procesa u radni spremnik te na kraju osloboditi taj dio spremnika. Naime, većina ostvarenja dinamičkog upravljanja spremnikom ne vraća traženi spremnik operacijskom sustavu sve do završetka procesa. Tako će početno zauzimanje spremnika osigurati da i naknadni zahtjevi koriste taj već dodijeljeni dio procesu. Ipak, potrebno je provjeriti je li takvo ponašanje i na sustavu koji se koristi u pojedinom slučaju.

10.2. Operacijski sustavi posebne namjene

Upravljanje različitih sustavima se međusobno znatno razlikuje. Negdje je dovoljan kratki upravljački program, dok je drugdje potreban složeni višezadaćni sustav.

Primjerice, osobno računalo bilo u uredu ili u kući, kao i radna stanica, nije osmišljeno za obavljanje samo jednog posla već mnoštvo njih. Međutim, zbog svoje opće namjene takvo računalo nema odgovarajuće mehanizme potrebne za uporabu u većini SRSV-a. Kao prvo, dimenzijama i cijenom bitno odudara od zahtjeva ugrađenih sustava. Nadalje, nema ugrađene mehanizme vremenske određenosti, kako ni u sklopovlju tako ni u programskoj okolini. Na primjer, kod osobnog računala gotovo je sasvim nebitno je li za prikaz nekog prozora na zaslonu potrebna sekunda, dvije, tri ili se neki proračun obavlja desetak ili više sekundi ili minuta, ali je ta vrsta neodređenosti nedozvoljena u SRSV-ima. Uredski operacijski sustavi i sustavi na radnim stanicama imaju vrlo lošu podršku vremenski uređenim zadacima i odzivu na vanjske događaje, pa su u većini slučajeva neupotrebljivi za SRSV-e, osim eventualno za one s blagim vremenskim ograničenjima.

U novije vrijeme pojavljuju se novi operacijski sustavi koji pokrivaju segment takozvanih prijenosnih i ručnih računala, bilo samostojećih ili povezanih s mogućnostima mobilnih telefona ili drugih uređaja. Primjeri takvih sustava su “pametni” mobilni telefoni (engl. *smartphones*), multimedijalni uređaji, čitači elektroničkih knjiga, ručna računala. Primjeri operacijskih sustava koje koriste navedeni uređaji su Android i iOS. Ne može se reći da su prethodni sustavi tipični ugrađeni sustavi. Dapače, navedeni su po svojstvima bliži općim operacijskim sustavima za stolna računala. Međutim, i ti operacijski nastoje proširiti područja svoje primjene u ugrađenim sustavima, primjerice za uređaje u automobilima, za “pametne” televizore i slično. Zato se i razvijaju u smjeru postizanja bar minimalnih svojstava potrebnih za takve sustave, tj. nastoje ostvariti mogućnosti za primjenu u sustavima s blagim vremenskim ograničenjima.

U pogledu mogućnosti za primjenu u SRSV-ima treba najprije izdvojiti operacijske sustave posebno izgrađene za tu primjenu. Tu primjerice spadaju QNX [Neutrino], Windriver [VxWorks], Enea [OSE], [MicroC/OS-II], [FreeRTOS] i slični operacijski sustavi. Njihovo korištenje ima svoje prednosti, ali i nedostatke.

U nastavku je opisan FreeRTOS. Posebnost FreeRTOS-a jest što je to sustav na nižoj razini od ostalih, programi i funkcije za obradu prekida su jače povezane sa samim operacijskim sustavom te zahtjevaju posebna znanja programera o načinima rada FreeRTOS-a. Ostali operacijski sustavi imaju uglavnom znatno odijeljene programe od jezgre.

10.2.1. Operacijski sustav FreeRTOS

FreeRTOS je namijenjen ugradbenim računalnim sustavima za rad u stvarnom vremenu i optimiran prema kriteriju malih zahtjeva prema sklopovlju (spremnički prostor i procesorska moć) te se može koristiti i na mikroupravljačima. Za razliku od prethodno navedenih, izvorni kôd FreeRTOS-a je slobodno dostupan (besplatan).

Korištenje FreeRTOS-a zahtjeva detaljnije poznavanje njegova sučelja i načina rada. U ovom odjeljku navedena su neka svojstva tog sustava kao i mogućnosti izgradnje programske potpore zasnovane na njemu.

Isključivanje nepotrebnih dijelova jezgre

Radi postizanja što manjeg zahtjeva na spremnički prostor, mnoge se operacije jezgre mogu izostaviti iz prevođenja. Primjerice, ako se sučelje, tj. jezgrina funkcija `Neka_Jezgrina_Funkcija` ne koristi onda u odgovarajućoj datoteci s postavkama treba postaviti 0 umjesto 1 u liniji (dodati liniju ako ne postoji):

```
#define INCLUDE_Neka_Jezgrina_Funkcija  0
```

Datoteka s postavkama je najčešće `FreeRTOSConfig.h` smještena u direktorij s programima koji koriste FreeRTOS. Koje se sve funkcije mogu isključiti iz prevođenja vidi se iz koda jer su takve funkcije ograđene mehanizmom opcionalnog uključivanja:

```
#if (INCLUDE_Neka_Jezgrina_Funkcija == 1)
    tip Neka_Jezgrina_Funkcija (parametri)
    {
        ...
    }
#endif  /* INCLUDE_Neka_Jezgrina_Funkcija */
```

Imenovanje varijabli

Imena varijabli i funkcija sadrže prefikse koji označavaju tip varijabli, odnosno povratne vrijednosti funkcije. Tako će cjelobrojna varijabla imati prefiks `x`, pozitivna cjelobrojna varijabla `ux`, kazaljka `p`, tj. `pux` za kazaljku na cjelobrojnu varijablu, `v` za funkciju tipa `void` i slično. Npr. prototip funkcije za stvaranje dretve jest:

```
BaseType_t xTaskCreate (
    TaskFunction_t pvTaskCode,
    const char * const pcName,
    uint16_t usStackDepth,
    void *pvParameters,
    UBaseType_t uxPriority,
    TaskHandle_t *pvCreatedTask
);
```

Zaštita pri korištenju dijeljenih sredstava sustava

Poprilično detaljno poznavanje rada sustava je neophodno kod FreeRTOS-a. Korištenje mnogih operacija mora biti ostvareno kao kritični odsječak, ali se to ostvarenje treba ostvariti u programu, nije uvijek ugrađeno u jezgrine funkcije. Primjerice, pri korištenju gomile (engl. *heap*) sučeljem `malloc` i `free` treba onemogućiti zamjenu s trenutne dretve na neku drugu radi očuvanja konzistentnosti strukture podataka kojom se upravlja gomilom. Primjerice, to se može napraviti sa:

```
    vTaskSuspendAll();
    pvReturn = malloc(xWantedSize);
    xTaskResumeAll();
```

Navedeni primjer prikazuje potrebu upravljanja sustavom na najnižoj razini u samom programu. Gornji primjer neće prekidati druge dretve, ali prekidi hoće. Zabrana prekida manjeg prioriteta od dretve može se napraviti s `taskENTER_CRITICAL()` (ponovna dozvola s `taskEXIT_CRITICAL()` ili svih prekida s `taskDISABLE_INTERRUPTS()`. Sva ova sučelja podrazumijevaju jednoprocesorsko računalo. U višeprocesorskim bi trebalo koristiti prikladnije sinkronizacijske mehanizme koji ostvaruju isključivanje i na takvim sustavima.

Pokretanje raspoređivača dretvi

Pri pokretanju sustava višedretvenost nije omogućena, niti ona to mora biti. Pokretanje višedretvenosti postiže se pozivom `vTaskStartScheduler()`. Funkcija koja (nakon inicijalizacije) preuzima kontrolu nad sustavom, stvara potrebne dretve i slično, može izgledati kao sljedeći primjer.

Isječak kôda 10.1. Primjer višedretvenosti u FreeRTOS-u

```
void vPocetnaFunkcija(void)
{
    TaskHandle_t xHandle = NULL;

    /* Inicijalizacija, stvaranje ostalih potrebnih objekata */
    /* ... */

    /* Stvaranje bar jedne dretve (prije pokretanja raspoređivača) */
    xTaskCreate(vDretva, "IME_DRETVE", VEL_STOGA, NULL, prioritet, &xHandle);

    /* ... stvaranje ostalih dretvi i potrebnih objekata */

    /* Pokretanje prioritetnog raspoređivača */
    vTaskStartScheduler();

    /* Kontrola neće doći ovdje dok se ne zastavi raspoređivač
     * od strane neke dretve s: vTaskEndScheduler();
     * tj. najčešće se ovdje nikad ne vraća! */

    /* primjer micanja dretve iz sustava */
    if (xHandle != NULL)
        vTaskDelete(xHandle);
}

void vDretva(void * pvParameters)
{
    for (;;)
    {
        /* Posao dretve */
    }
}
```

Same dretve trebaju biti oblikovane kao funkcije koje nikada ne završavaju. Odnosno, ako trebaju završiti onda one (ili druge dretve) trebaju pozvati `vTaskDelete(pxTask)`. Struktura početne funkcije dretve treba, dakle izgledati kao u primjeru.

Manje zahtjevne dretve – niti

Višedretvenost može za neke sustave biti suviše zahtjevna na spremnički prostor jer za svaku dretvu treba opisnik i zaseban stog. Za takve sustave (ali i druge), umjesto pravih dretvi ili i paralelno s njima mogu se koristiti jednostavnije dretve, nazovimo ih *nitima* – u FreeRTOS-u su nazvane *co-routine*. Sve niti jedne aplikacije dijele isti stog, funkcije upravljanja su jednostavnije, ali ne mogu se sve jezgirne funkcije koristiti. Zbog zajednička stoga potrebno je posebno paziti i na oblikovanje aplikacije.

Međudretvena sinkronizacija i komunikacija

Od mogućnosti međudretvene komunikacije treba izdvojiti redove poruka, semafore: binarne, opće, binarne s nasljeđivanje prioriteta (izvorno *mutex semaphore*) i alarme. Ako dretva treba čekati na više događaja (poruku ili semafor) mogu se koristiti mehanizmi skupova redova (engl. *queue sets*), gdje se dretva može blokirati dok bar jedan od redova u skupu ne postane prolazan (ima poruku ili semafor postane prolazan).

Pozivi jezgrinih funkcija iz prekidnih funkcija

Većina funkcija za upravljanje dretvama i povezanim objektima ima i inačice pripremljene za poziv iz obrade prekida (engl. *from interrupt service routine*) sa sufiksom `FromISR`. Primjerice, funkcija za slanje poruke u red poruka `xQueueSend` ima alternativnu inačicu `xQueueSend FromISR` za korištenje iz obrade prekida.

```
BaseType_t xQueueSend (
    QueueHandle_t xQueue,
    const void * pvItemToQueue,
    TickType_t xTicksToWait
);
BaseType_t xQueueSendFromISR (
    QueueHandle_t xQueue,
    const void *pvItemToQueue,
    BaseType_t *pxHigherPriorityTaskWoken
);
```

Preko trećeg parametra funkcije `xQueueSendFromISR` dobiva se informacija o tome je li se dodavanjem poruke u red oslobodila neka prioritetnija dretva od trenutno aktivne (i prekinute ovim prekid), u kom slučaju bi trebalo pozvati raspoređivač. Skica takve prekidne funkcije dana je u nastavku.

```
void vPrekidnaFunkcija(void)
{
    QueueHandle_t xQueue = dohvati_red();
    const void *pvItemToQueue = dohvati_poruku();
    BaseType_t pxHigherPriorityTaskWoken;

    xQueueSendFromISR(xQueue, &pvItemToQueue, &pxHigherPriorityTaskWoken);
    if (pxHigherPriorityTaskWoken)
    {
        portSAVE_CONTEXT();
        vTaskSwitchContext();
        portRESTORE_CONTEXT();
    }
    asm volatile ( "reti" );
}
```

U primjeru treba primijetiti da se spremanje konteksta i obnova konteksta radi 'ručno' zato što se radi o funkciji koja se zove iz obrade prekida (sama funkcija `vTaskSwitchContext()` samo odabire najprioritetniju za aktivnu dretvu, ali ne radi promjenu konteksta).

Ovisno o sklopovlju na koji se FreeRTOS stavlja obrade prekida mogu se prekidati prioritetnijim prekidima (kada to sklopovlje dozvoljava). U tom slučaju treba pažljivo odabrati prioritete prekida i dretvi i programskih prekida i sklopovskih prekida.

FreeRTOS je operacijski sustav na vrlo niskoj razini upravljanja, ali zato omogućuje ugradnju u sustave s minimalnim spremničkim prostorom, npr. u sustavu koji ima samo 4 KB radnog spremnika za podatke.

10.3. Svojstva različitih tipova operacijskih sustava

Odabir operacijskog sustava za pojedine primjene treba obaviti sukladno očekivanjima funkcionalnosti i usklađenosti s okolinom u koju se ugrađuje. Također treba planirati mogućnosti ažuriranja i nadogradnje kroz predviđeni životni vijek sustava. Cijena nabavke i podrška proizvođača pri održavanju trebaju također biti jedan od razloga pri odabiru za "dugovječne sustave". Slika 10.2. prikazuje načelna svojstva različitih kategorija operacijskih sustava.

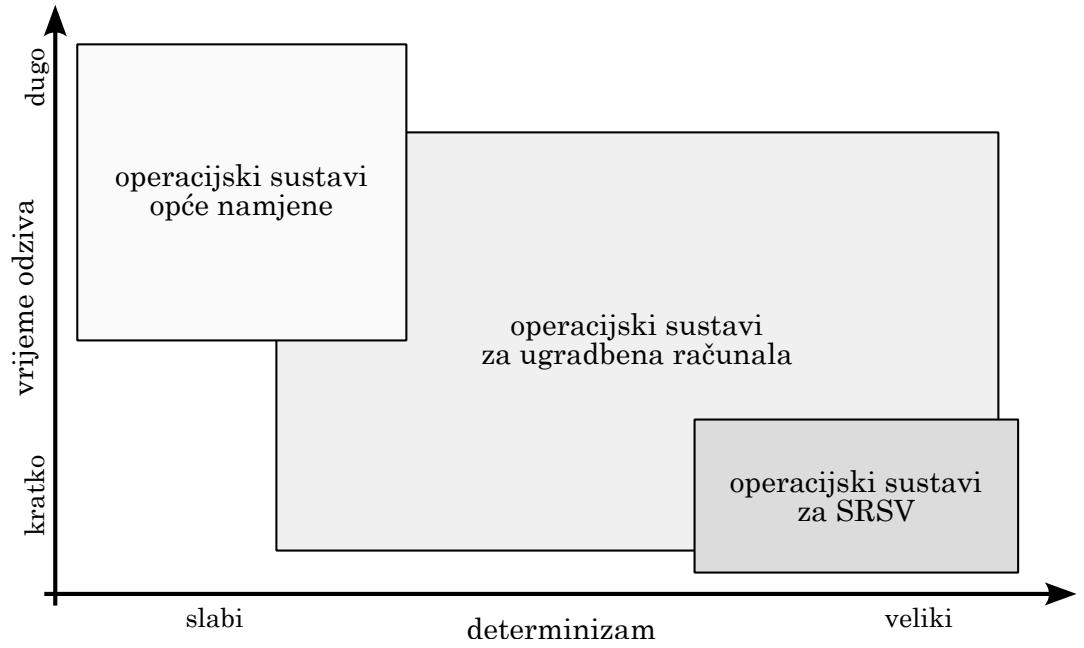

Slika 10.2. Vremenska svojstva različitih sustava

Operacijski sustavi opće namjene građeni su generički, kao i samo sklopovlje za takva računala. Oni su napravljeni da mogu raditi mnoštvo stvari uz zadovoljavajuću kvalitetu i nisku cijenu. Promatrajući svojstva takvih sustava u kontekstu uporabe za upravljanje vremenski kritičnih procesa uočavaju se neki nedostaci koji su posljedica otvorenosti operacijskih sustava opće namjene raznim sklopovskim i programskim rješenjima. Zato je odziv takvih sustava vrlo nepredvidiv, često neprihvatljivo dug, a kako bi se takvi sustavi mogli koristiti za upravljanje procesa sa strogim vremenskim ograničenjima. Za nekritične elemente sustava, gdje su zadana blaža vremenska ograničenja, moguće je odabrati i operacijske sustave za opću uporabu. Pravilnim podešavanjem sustava može se znatno poboljšati ponašanje sustava u smislu pouzdanosti

i predvidivosti ponašanja.

S druge strane, operacijski sustavi posebno osmišljeni za sustave sa strogim vremenskim ograničenjima, kao što su to operacijski sustavi za rad u stvarnom vremenu te operacijski sustavi za ugrađena računala, imaju, naravno, znatno bolja vremenska svojstva. Nedostatak takvih sustava je u manjoj podršci sklopovlju i dobavljivosti gotovih programskih rješenja.

Između pravih operacijskih sustava za rad u stvarnom vremenu i operacijskih sustava opće namjene postoji područje u kojemu se nalaze prilagođeni operacijski sustavi opće namjene, ali značajno boljih svojstava. Prednosti takvih sustava su u dostupnosti gotovo jednakih razvojnih alata i podržanih protokola kao i u sustavima opće namjene.

10.3.1. Operacijski sustavi za rad u stvarnom vremenu

Primjere zašto neki operacijski sustavi opće namjene nisu pogodni za kritične sustave mogu se potražiti iz raznih studija. Jedna od takvih uspoređuje eksperimentalne rezultate provedene na Linux sustavima s jezgrama 2.4 i 2.6 te s prilagođenim Linux sustavima za uporabu u SRSV-ima. U eksperimentu su mjerena kašnjenja od trenutka pojave događaja do početka njegove obrade (engl. *preemption latency*). Tablica 10.1. prikazuje rezultate jednog eksperimenta.

Tablica 10.1. Izmjerena kašnjenja do početka obrade prekida u μs ([Laurich, 2004])

	2.4 Linux	2.6 Linux	2.4 Linux RTAI	2.4 Linux LXRT
Prosječna kašnjenja	12 – 14	12 – 14	8 – 10	10 – 12
Najveća kašnjenja	4446	578	42	50

Prosječna kašnjenja su samo malo veća kod običnih sustava, međutim, kada se pogledaju svi slučajevi i izvuku najgori slučajevi onda se jasno vidi da su operacijski sustavi opće namjene značajno lošiji.

Slika 10.3. prikazuje vremena odziva na Linux-u s inačicom jezgre 2.6.24 i njegovoj SRSV inačici. Kao što se vidi iz slike, vrijeme odziva na događaje je znatno kraće za prilagođenu inačicu Linux operacijskog sustava i ne prelazi 50 [μs]. S druge strane, standardni Linux, iako u prosjeku događaje obrađuje s kašnjenjem od oko 50 [μs] ima značajan broj odziva čija su kašnjenja za događajem veća i od nekoliko milisekundi!

Produljena kašnjenja u početku obrade, premda vrlo rijetka, za mnoge sustave nisu prihvatljiva. S druge strane, kod drugih sustava rijetka kašnjenja u obradi događaja ne moraju nužno označavati katastrofalnu grešku, već možda samo smanjenje kvalitete ili se njihov utjecaj može i zanemariti.

Ako je zaista potrebno, neki elementi sustava moraju se izvoditi na nekom od operacijskih sustava za rad u stvarnom vremenu. Svojstva takvih sustava koji se danas mogu pronaći na tržištu su približno jednaka. Ono što se može razlikovati jest u podršci prema podržanom sklopovlju, alatima za razvoj programa, skupu podržanih protokola i standarda te podršci koju proizvođač pruža pri razvoju. Poželjno je odabrati sustave s podrškom za standardna POSIX sučelja za rad u stvarnom vremenu kako bi se isti programi u budućnosti mogli jednostavnije prenijeti na druge platforme.

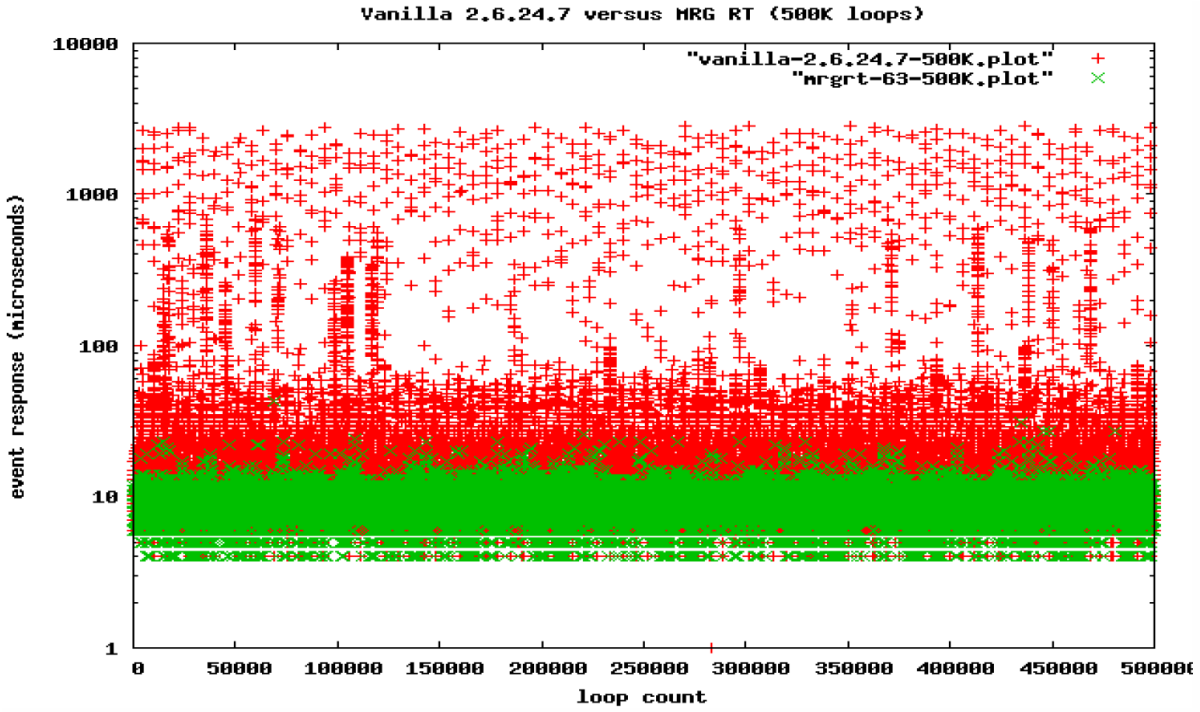

Legenda: svaki znak "+" označava jedan događaj u običnom Linux sustavu dok znak "×" događaj u prilagođenom Linuxu (SRSV inačici); ordinata predstavlja vrijeme odziva, a apscisa redni broj događaja

Slika 10.3. Usporedba vremena odziva na Linux sustavima ([Clark, 2008])

10.3.2. Operacijski sustavi opće namjene

Operacijski sustavi opće namjene mogu biti dostatni za nekritične elemente sustava (npr. neki od Windows operacijskih sustava). Prednosti korištenja tih sustava su u dostupnosti svih tehnologija, protokola, standarda i alata za njih, kao i mogućnosti njihovog korištenja na svakom osobnom računalu. Odabir jednog od njih i njihova međusobna sukladnost i mogućnost suradnje pruža sigurnost u nastavak razvoja i održavanja (s obzirom na to da su ti sustavi zastupljeni u velikoj većini današnjih računalnih sustava).

"Alternativno" rješenje može biti korištenje sustava zasnovanog na Linux operacijskom sustavu. Linux operacijske sustave u današnje vrijeme razvija dobrovoljna zajednica, ali često i uz pomoć većih tvrtki (primjerice Google). Iako su besplatni za korištenje, Linux sustavi su (barem) usporedivi s komercijalnim sustavima u pogledu učinkovitosti, dostupnosti programa i alata za razvoj. Kao i za Windows sustave i za Linux se može predvidjeti da će se u bližoj budućnosti nastaviti razvijati.

Iako značajno lošiji svojstava od operacijskih sustava za rad u stvarnom vremenu, operacijski sustavi opće namjene se ipak mogu primijeniti u nekim slučajevima. Napretkom tehnologije današnja su računala vrlo brza, pa se nedostaci u nedeterminizmu ponekad mogu nadomjestiti brzinom rada, ali samo za sustave s blažim vremenskim ograničenjima.

10.3.3. Prilagođeni operacijski sustavi opće namjene

U području između operacijskih sustava za rad u stvarnom vremenu i onih opće namjene može se izdvojiti nekoliko značajnijih. Neki od navedenih sustava se više ne prodaju/održavaju – nisu opstali ili su zamijenjeni drugim sustavima, ali su ipak navedeni zbog ideja koje su koristili radi poboljšanja svojstva izvornih sustava u smjeru korištenja u SRSV-ima.

Real-Time Linux

Real-Time Linux je jezgra operacijskog sustava koja nastaje primjenom dodatka (engl. *patch*) `CONFIG_PREEMPT_RT` na izvorni kod Linux jezgre. Službeni naziv dodatak je dobio po svojoj osnovnoj funkciji – mogućnosti prekidanja potencijalno dugotrajnih jezgrinih funkcija (dugotrajnih s aspekta SRSV-a). Takve su dugotrajne funkcije osnovni razlog nemogućnosti korištenja obične Linux jezgre u SRSV-ima.

Na stranicama koje opisuju taj dodatak [Real-Time Linux] nalaze se i korisne preporuke kako koristiti Linux jezgru u SRSV okruženju (s tim i bez tog dodatka) s obzirom na svojstva nekih elemenata jezgre kao i Intelove arhitekture.

RTLinux

Sličnog imena, ali drukčije ostvarenje koristi RTLinux. RTLinux ima svoju zasebnu jezgru koja izvodi kritične zadatke upravljanja (koji se pripremaju za tu jezgru). Linux je u tom sustavu samo jedan proces, i to proces s najmanjim prioritetom. Svi programi pripremljeni za jezgru imaju veći prioritet od Linux-a. Linux, i svi procesi u njemu vide RTLinux kao sklopovlje – RTLinux jezgra "maskira" sklopovlje pravom Linux-u. Komunikacija zadataka kojima upravlja RTLinux i zadataka kojima upravlja Linux može se ostvariti preko zajedničkog spremnika te preko FIFO struktura. I jedni i drugi se u Linux-u vide kao uređaji, dok ih dretve u RTLinux-u koriste posebnim sučeljem. Navedeno prikazuje slika 10.4.

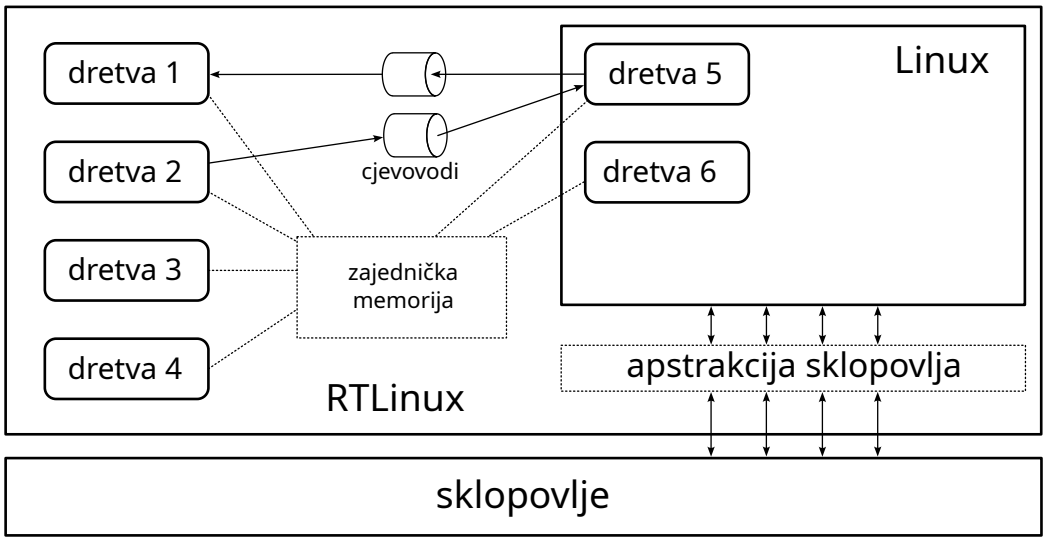

Slika 10.4. RTLinux arhitektura

Osim navedena dva ostvarenja postoji (postojalo je) i mnoštvo drugih sličnih, primjerice: Lineo – Embedix Realtime, REDSonic – REDICE Linux, MontaVista Real Time Extensions, LynuxWorks – BlueCat RT, TimeSys – Linux/Real-Time+. Uobičajeno rješenje koje koristi većina navedenih sustava je korištenje vlastite jezgre u kojoj se sam Linux sustav izvodi kao zaseban proces.

Microsoft neke svoje opće operacijske sustave nudi i u posebnim izvedbama. Jedne od njih su prilagođene inačice operacijskih sustava za stolna računala (Windows 10 IoT Enterprise, prethodno Windows Embedded Standard) u kojima su izbačeni nepotrebni elementi, neki drugi dodatno prilagođeni novim okolinama. Druge izvedbe su posebno prilagođene ugradbenim računalima namijenjene korištenju u multimedijskim uređajima (Windows 10 IoT Mobile), odnosno, upravljačkim sustavima (Windows 10 IoT Core, prethodno Embedded Compact, Embedded CE, Windows CE). Gotovo identično sučelje prema operaciskom sustavu u svim navedenim inačicama omogućava da se već postojeća baza programera iskoristi i za programiranje aplika-

cija za ugradbene i upravljačke sustave.

10.3.4. Odabir operacijskih sustava

Analizom potreba za pojedine probleme treba odabrati prikladan operacijski sustav. Ako su vremenska ograničenja vrlo stroga, za taj dio sustava potrebno je odabrati prikladan OS za SRSV. Za manje kritične komponente poželjno je ipak odabrati neki opći operacijski sustavi (Windows ili Linux) ili njihove modifikacije zbog veće dostupnosti razvojnih alata, podrške raznim tehnologijama i protokolima, kao i predviđenom životnom vijeku, njihovu daljem razvoju i podršci. Odabirom operacijskih sustava s kontinuiranim razvojem i ogromnom korisničkom bazom maksimizira se rok podrške za operacijske sustave, pa tako posredno i podršku za većinu novih tehnologija koje će se pojaviti u skoroj budućnosti, a koji bi mogli postati potrebni u procesu unaprjeđenja sustava.

Korištenjem standardnih tehnologija podržanih od strane više proizvođača omogućuje se modularna izgradnja sustava, koji po sastavu, sklopovski i programski može biti i heterogen. Odluka o odabiru operacijskog sustava za pojedine elemente sustava u takvom slučaju ne mora biti konačna, već se on može promijeniti i naknadno bez značajnijeg dodatnog truda u prilagodbi aplikacija za taj sustav.

Konačno, ponekad ipak može biti potrebno izgraditi vlastiti sustav jer postojeći iz raznih razloga ne odgovaraju (cijenom, svojstvima, zahtjevima na sklopovlje, ...).

Pitanja za vježbu 10

1. Koja je uloga operacijskog sustava u računalu?
2. Koja svojstva ograničavaju uporabu operacijskog sustava u ugrađenim sustavima?
3. Opisati mehanizam prihvata prekida sa stanovišta operacija koje poduzima operacijski sustav te sa stanovišta njegova iskorištenja. Navesti prednosti i nedostatke različitih načina prihvata prekida.
4. Koju podršku nude operacijski sustavi za upravljanje napravama mehanizmom prekida? Što ako bi obrada mogla duže potrajati?
5. Koja su svojstva upravljanja spremničkim prostorom bitna u kontekstu korištenja u SRSV-ima?
6. S obzirom na predviđenu uporabu opisati različite kategorije operacijskih sustava.
7. Po čemu se operacijski sustavi predviđeni za SRSV-e bitno razlikuju od ostalih operacijskih sustava?
8. Navesti osnovna svojstva FreeRTOS-a u kontekstu ugrađenih sustava i SRSV-a.
9. Opisati operacijske sustave RTLinux te Real-Time Linux. Kako prvi i drugi koriste Linux?
10. Kada je potrebno koristiti posebne operacijske sustave za SRSV-e, a kada je moguće iskoristiti i obične operacijske sustave?
11. Pri korištenju običnih operacijskih sustava, što se sve može napraviti da se poboljšaju

svojstva sustava (programa i operacijskog sustava) za primjenu u SRSV-ima?

Literatura

[Budin, 2011] Leo Budin, Marin Golub, Domagoj Jakobović, Leonardo Jelenković, *Operacijski sustavi*, Element, 2011.

[Buttazzo, 2000] Giorgio C. Buttazzo, *Hard real-time computing systems: predictable scheduling algorithms and applications*, Kluwer Academic Publishers, 2000.

[Đonlagić, 1994] Dali Đonlagić, *Osnove projektiranja neizrazitih (fuzzy) regulacijskih sustava*, KoREMA, 1994.

[Grantham, 1993] Walter J. Grantham, Thomas L. Vincent, *Modern control systems: analysis and design*, Wiley, 1993.

[Jantsch, 2004] Axel Jantsch, *Modeling Embedded Systems and SoCs: Concurrency and Time in Models of Computation*, Morgan Kaufmann Publishers, 2004.

[Kovačić, 2006] Zdenko Kovačić, Stjepan Bogdan, *Fuzzy Controller Design: Theory and Application*, Taylor & Francis, 2006.

[Krishna, 1997] C. M. Krishna, Kang G. Shin, *Real-time systems*, McGraw-Hill, 1997.

[Labrosse, 2002] J. J. Labrosse, *MicroC/OS-II: The Real Time Kernel, 2nd edition*, CMP Books, 2002.

[Laplante, 2012] Phillip A. Laplante, Seppo J. Ovaska, *Real-time systems design and analysis: Tools for the practitioner, 4th ed.*, IEEE Press, 2012.

[Levi, 1990] Shem-Tov Levi, Ashok K. Agrawala, *Real-time system design*, McGraw-Hill, 1990.

[Liu, 2000] Jane W. S. Liu, *Real-time systems*, Prentice Hall, 2000.

[Nissanke, 1997] Nimal Nissanke, *Realtime systems*, Prentice Hall, 1997.

[Rajkumar, 1991] R. Rajkumar, *Synchronization in real-time systems: A Priority Inheritance Approach*, Kluwer Academic Publishers, 1991.

[Silberschatz, 2002] Abraham Silberschatz, Greg Gagne, Peter Baer Galvin, *Operating System Concepts, 6th edition*, Wiley, 2002.

[Baruah, 2003] Sanjoy K. Baruah, Joel Goossens, *Rate-Monotonic Scheduling on Uniform Multiprocessors*, IEEE Trans. on Computers, Vol. 52, No. 7, July 2003.

[Jain, 1994] Kamal Kumar Jain and V. Rajaraman, *Lower and Upper Bounds on Time for Multiprocessor Optimal Schedules*, IEEE Trans. on Parallel and Distributed Systems, Vol. 5, No. 8, August 1994.

[Liu, 1973] C. L. Liu and James W. Layland, *Scheduling Algorithms for Multiprogramming in a Hard-Real-Time Environment*, Journal of the ACM, Vol. 20, No. 1, January 1973.

[Lopez, 2004] Jose M. Lopez, Jose L. Diaz, and Daniel F. Garcia, *Minimum and Maximum Utilization Bounds for Multiprocessor Rate Monotonic Scheduling*, IEEE Trans. on Parallel and Distributed Systems, Vol. 15, No. 7, July 2004.

[Murphy, 2000] N. Murphy, *Watchdog Timers, Embedded systems Programming*, November 2000, p. 112.

[Murphy, 2001] N. Murphy, M. Barr, *Watchdog Timers, Embedded systems Programming*, October 2001, pp. 79-80.

[Budiselić, 2011] Ivan Budiselić, *Dinamičko programiranje i problemi raspoređivanja*, seminarski rad (doktorski studij), 2011, http://www.zemris.fer.hr/~leonardo/srsv/dodatno/Budiselic-Dinamicko-programiranje.pdf.

[Bogunović, 2012] Nikola Bogunović, *Oblikovanje programske potpore, materijali za predavanja*, FER2 preddiplomski studij, http://www.fer.unizg.hr/predmet/opp.

[Clark, 2008] Clark Williams, *An Overview of Realtime Linux*, http://people.redhat.com/bche/presentations/realtime-linux-summit08.pdf.

[Jelenković, 2010] Leonardo Jelenković, *Osnovni koncepti operacijskih sustava, prezentacija i primjeri*, 2010., http://www.zemris.fer.hr/~leonardo/os/Osnovni_koncepti_OSa.

[Jones, 1997] M. Jones, *What really happened on Mars?*, http://research.microsoft.com/en-us/um/people/mbj/mars_pathfinder/mars_pathfinder.html.

[Laurich, 2004] Peter Laurich, *A comparison of hard real-time Linux alternatives*, 2004, http://www2.hs-augsburg.de/informatik/vorlesungen/echtzeit/script/AT3479098230.html.

[Linux scheduling] *Linux Programmer's Manual: sched – overview of scheduling APIs*, http://man7.org/linux/man-pages/man7/sched.7.html.

[POSIX] *POSIX, 7. izdanje*, 2008, http://pubs.opengroup.org/onlinepubs/9699919799.

[Futex] *Futex – fast user-space locking*, 2011, https://man7.org/linux/man-pages/man2/futex.2.html.

[QNX, 6.3] *The QNX Neutrino Microkernel – Scheduling*, 2013., http://www.qnx.com/developers/docs/6.3.0SP3/neutrino/sys_arch/kernel.html#SCHEDULING

[Thread-Safety] *POSIX: Thread-Safety*, 2008, http://pubs.opengroup.org/onlinepubs/9699919799/functions/V2_chap02.html#tag_15_09_01.

[Android] *Android (operacijski sustav)*, http://www.android.com.

[FreeRTOS] *FreeRTOS*, http://www.freertos.org/.

[iOS] *iOS (operacijski sustav)*, http://www.apple.com/ios/.

[Linux] *Linux operating system*,
http://www.kernel.org.

[Neutrino] *QNX Neutrino Realtime Operating System*,
http://www.qnx.com/products/neutrino-rtos/.

[OSE] *Enea OSE*,
http://www.enea.com/solutions/rtos/ose/.

[RTLinux] Victor Yodaiken, *The RTLinux Manifesto)*,
http://www.yodaiken.com/papers/rtlmanifesto.pdf.

[Real-Time Linux] *Real-Time Linux (CONFIG_PREEMPT_RT)*,
https://rt.wiki.kernel.org.

[VxWorks] *Windriver VxWorks real time system*,
http://www.windriver.com/products/vxworks/.

[Windows IoT] *Windows IoT*,
https://developer.microsoft.com/en-us/windows/iot.