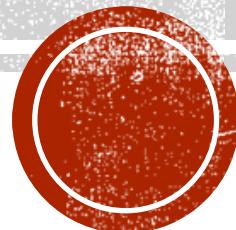


UPRAVLJANJE MEMORIJOM U C-U

Arhitektura računala 2



Andi Škrgat

SADRŽAJ

- Aplikacijsko binarno sučelje Windows x64 ABI
- Pohranjivanje podataka na stogu i gomili
- Rukovanje gomilom
- Mapiranje datoteka u memoriju računala
- Korištenje binarnog zapisivanja

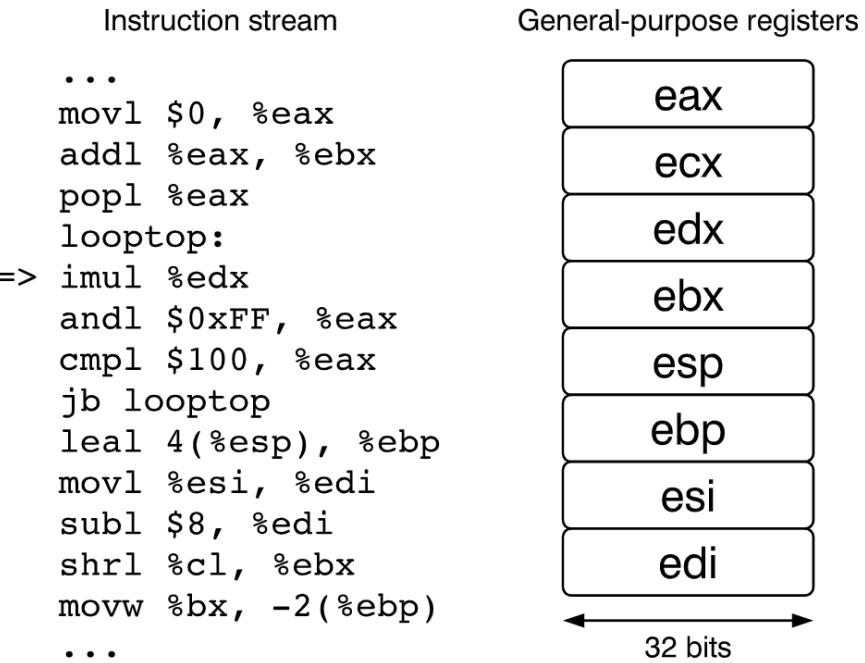
Let's start!



X86 ARHITEKTURA

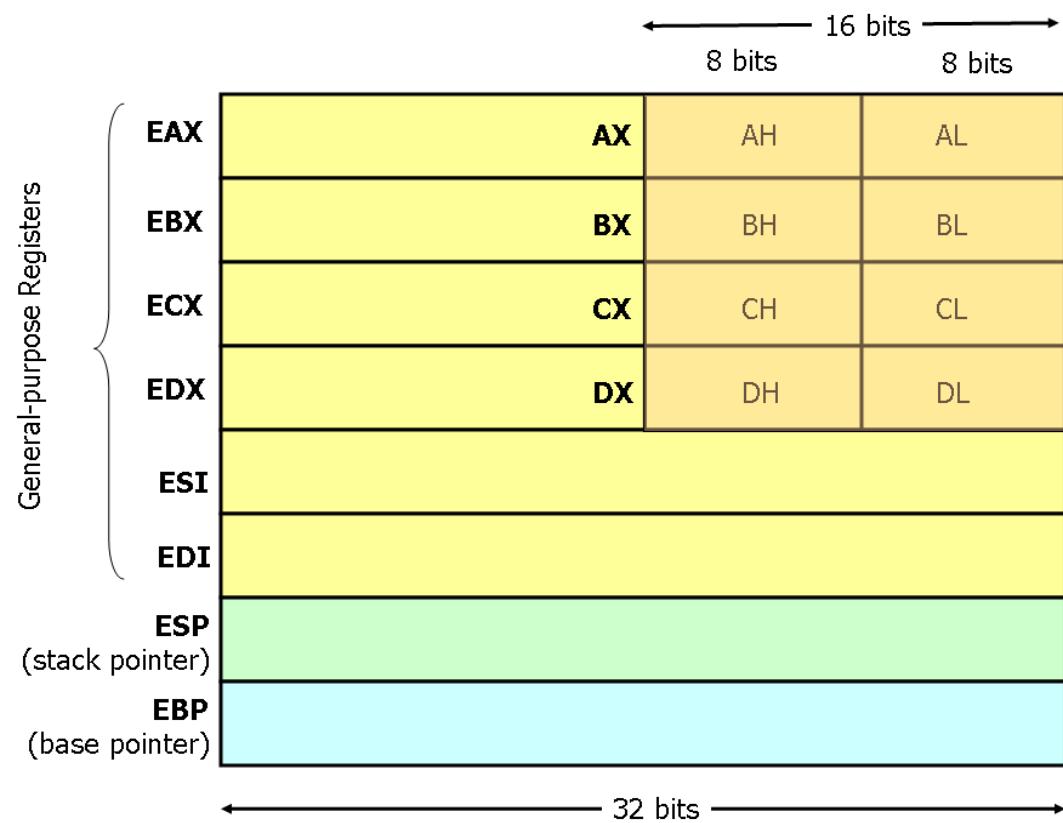
- Kompatibilna ekstenzija x86 arhitekture – podržava i 32-bitan način rada i 64
- AMD64 i Intel64
 - Instrukcijski set im je jako sličan
- Kompatibilna unazad
- Puno načina adresiranja
 - reg + reg
 - reg
 - disp16 (a 16bit displacement)
 - reg + reg + disp8/16 (an 8 or 16bit displacement)
 - reg + disp8/16

Simplified model of x86 CPU



X86 ARHITEKTURA

64-bit register	Lower 32 bits	Lower 16 bits	Lower 8 bits
rax	eax	ax	al
rbx	ebx	bx	bl
rcx	ecx	cx	cl
rdx	edx	dx	dl
rsi	esi	si	sil
rdi	edi	di	dil
rbp	ebp	bp	bpl
rsp	esp	sp	spl
r8	r8d	r8w	r8b
r9	r9d	r9w	r9b
r10	r10d	r10w	r10b
r11	r11d	r11w	r11b
r12	r12d	r12w	r12b
r13	r13d	r13w	r13b
r14	r14d	r14w	r14b
r15	r15d	r15w	r15b



X86 ABI

- Konvencije pozivanja
 - Caller clean-up
 - cdecl
 - Parametri na stog
 - EAX, ECX, EDX očuvani od strane pozivatelja
 - Integeri i adrese se vraćaju u EAX registru
 - Realni brojevi u ST0 x87 registru
 - syscall
 - EAX, ECX, EDX nisu očuvani
 - optlink
 - Parametri preko registara EAX, EDX, ECX, ST0-ST3
 - Povratna vrijednost EAX i ST0



X86 ABI

- Callee clean-up
 - pascal
 - slijeva na desno argumenti na stog
 - Povratne vrijednosti u AL(8-bit), AX(16-bit), EAX(32-bit), DX:AX(32-bit on 16-bit systems)
 - stdcall
 - S desna nalijevo argumenti na stog
 - Win32 API
 - Microsoft fastcall
 - Prva 2 argumenta u EDX i ECX ostali na stog
 - S desna nalijevo
 - Microsoft vectorcall, Borland registers, Watcom register, TopSpeed, Clarion, JPI, safecall



MICROSOFT X64 KONVENCija POZIVANJA

- Prva 4 cijelobrojna parametra(i pointeri) -> RCX, RDX, R8 i R9 registri
- Prva 4 realna parametra -> XMM0 – XMM3 – SSE registri
- Ostatak na stog
- Pointer ili cijelobrojna povratna vrijednost -> RAX registar
- Realna povratna vrijednost -> XMM0
- RAX, RCX, RDX, R8-R11 promjenjivi
- RBX, RBP, RDI, RSI, R12-R15 nepromjenjivi
- RSP je pokazivač na vrh stoga



IZVORNI KOD PREVOĐENJE

```
#include<iostream>
|
int proc(int a, int b){
    int c[2];
    c[0]=a-b;
    c[1]=2*c[0];
    return c[0]+c[1];
}

int main(){
    std::cout << proc(3,1) << std::endl;
}
```



NEOPTIMIZIRANO PREVOĐENJE

```
.file    "arh.c"
.intel_syntax noprefix
.text
.globl  proc
.def    proc; .scl   2;      .type   32;      .edef
.seh_proc        proc

proc:
    push   rbp //rbp na stog
    .seh_pushreg    rbp
    mov    rbp, rsp //premjesti pokazivač na vrh stoga u rbp
    .seh_setframe   rbp, 0
    and   rsp, -16
    sub   rsp, 16
    .seh_stackalloc 16
    .seh_endprologue
    mov    DWORD PTR 16[rbp], ecx
    mov    DWORD PTR 24[rbp], edx
    mov    eax, DWORD PTR 16[rbp]
    sub   eax, DWORD PTR 24[rbp] //c[0] = a - b
    mov    DWORD PTR -8[rbp], eax
    mov    eax, DWORD PTR -8[rbp]
    add   eax, eax //c[1] = 2*c[0]
    mov    DWORD PTR -4[rbp], eax
    mov    edx, DWORD PTR -8[rbp]
    mov    eax, DWORD PTR -4[rbp]
    add   eax, edx // |c[0] + c[1]
    mov    rsp, rbp
    pop   rbp
    ret
    .seh_endproc
    .def    __main; .scl   2;      .type   32;      .edef
    .globl main
    .def    main; .scl   2;      .type   32;      .edef
    .seh_proc        main

main:
    push   rbp
    .seh_pushreg    rbp
    mov    rbp, rsp
    .seh_setframe   rbp, 0
    and   rsp, -16
    sub   rsp, 32
    .seh_stackalloc 32
    .seh_endprologue
    call   __main
    mov    edx, 1
    mov    ecx, 3
```



OPTIMIZIRANO PREVODENJE

```
.file  "main.c"
.intel_syntax noprefix
.text
.def  __main; .scl  2;      .type  32;      .endef
.section .rdata,"dr"
.LC0:
.ascii "%d\12\0"
.section      .text.startup,"x"
.p2align 4,,15
.globl main
.def  main;   .scl  2;      .type  32;      .endef
.seh_proc     main
main:
sub   rsp, 40
.seh_stackalloc 40
.seh_endprologue
call  __main
mov   edx, 1
mov   ecx, 3
call  proc
mov   edx, eax
lea    rcx, .LC0[rip]
call  printf
xor   eax, eax
add   rsp, 40
ret
.seh_endproc
.ident "GCC: (x86_64-win32-seh-rev0, Built by MinGW-W64 project) 8.1.0"
.def  proc;   .scl  2;      .type  32;      .endef
.def  printf; .scl  2;      .type  32;      .endef
.file  "arh22.c"
.intel_syntax noprefix
.text
.p2align 4,,15
.globl proc
.def  proc;   .scl  2;      .type  32;      .endef
.seh_proc     proc
.proc:
.seh_endprologue
sub   ecx, edx
lea    eax, [rcx+rcx*2]
ret
.seh_endproc
.ident "GCC: (x86_64-win32-seh-rev0, Built by MinGW-W64 project) 8.1.0"
```



option	optimization level	execution time	code size	memory usage	compile time
-O0	optimization for compilation time (default)	+	+	-	-
-O1 or -O	optimization for code size and execution time	-	-	+	+
-O2	optimization more for code size and execution time	--		+	++
-O3	optimization more for code size and execution time	---		+	+++
-Os	optimization for code size		--		++
-Ofast	O3 with fast none accurate math calculations	---		+	+++



ALOKACIJA NA STOGU

```
#include<iostream>

int main(void) {

    int x = 1;
    int y = 2;
    int z = 3;

    std::cout << "Adresa x: " << &x << std::endl;
    std::cout << "Adresa y: " << &y << std::endl;
    std::cout << "Adresa z: " << &z << std::endl;

}
```

```
C:\Users\Korisnik\Desktop\C++Arh\Stack>StackAdresses
Adresa x: 0x61fe1c
Adresa y: 0x61fe18
Adresa z: 0x61fe14
```

```
C:\Users\Korisnik\Desktop\C++Arh\Stack>
```



JOŠ O STOGU...

- Iako imamo više tipova objekata, rezultat će biti isti (ako debugiramo u VSC onda će se dodati bajtovi između objekata kao „safety guards”, zbog overflowa i slično, ali ovdje su kontinuirano)

```
#include <iostream>

class VectorInt {
public:
    int x, y, z;

    VectorInt() : x(1), y(2), z(3) {}

};

class VectorFloat {
public:
    float x, y, z;

    VectorFloat() : x(4), y(4), z(4) {}

};

int main(void) {

    VectorInt intArr[2];

    VectorFloat floatArr[2];

    std::cout << "Adresa int1: " << &intArr[0] << std::endl;
    std::cout << "Adresa int2: " << &intArr[1] << std::endl;
    std::cout << "Adresa float1: " << &floatArr[0] << std::endl;
    std::cout << "Adresa float2: " << &floatArr[1] << std::endl;

}
```



```
C:\Users\Korisnik\Desktop\C++Arh\Stack>g++ StackDifferentObjects.cpp
```

```
C:\Users\Korisnik\Desktop\C++Arh\Stack>a
```

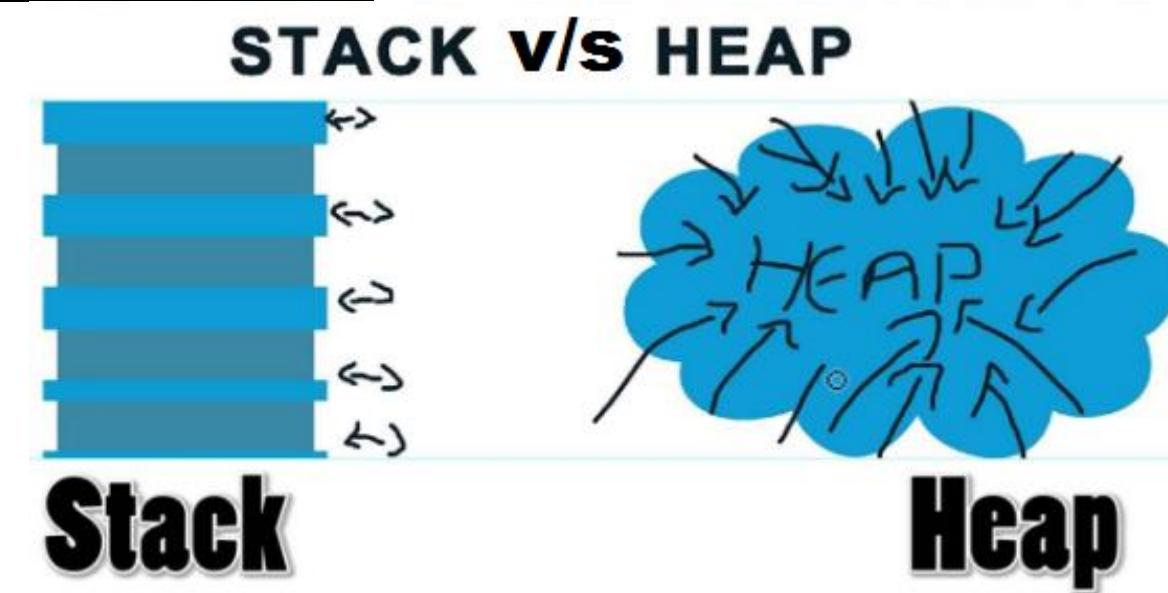
```
Adresa int1: 0x61fdf0
```

```
Adresa int2: 0x61fdfe
```

```
Adresa float1: 0x61fdd0
```

```
Adresa float2: 0x61fddc
```

```
C:\Users\Korisnik\Desktop\C++Arh\Stack>
```



ALOKACIJA NA HEAPU

```
#include <iostream>

int main(void) {

    int* x = new int;
    int* y = new int;
    int* z = new int;

    std::cout << "Adresa x: " << x << std::endl;
    std::cout << "Adresa y: " << y << std::endl;
    std::cout << "Adresa z: " << z << std::endl;

    delete x;
    delete y;
    delete z;

}
```

C:\Users\Korisnik\Desktop\C++Arh\Stack>g++ HeapAdresses.cpp

C:\Users\Korisnik\Desktop\C++Arh\Stack>a

Adresa x: 0x7024f0

Adresa y: 0x702510

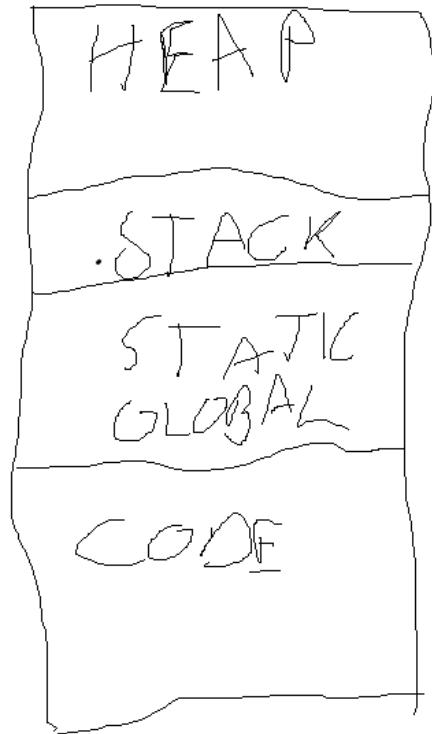
Adresa z: 0x702530

C:\Users\Korisnik\Desktop\C++Arh\Stack>



GOMILA VS STOG

Veće adrese



Manje adrese

Windows OS, na Linuxu su adrese stoga
veće od adresa koje pripadaju gomili

- Stog koristiti kad god je to moguće
- Rad sa stogom znači doslovno pomicanje pokazivača na vrh stoga -> brzina -> praktički 1CPU instrukcija
- Objekti su na stogu samo u onom bloku u kojem su inicijalizirani -> zato im ne možemo pristupiti kada izademo iz bloka
- Gomilu koristiti samo u situacijama kada nam treba puno memorije <- veličina stoga ~ 1-2MB
- Gomila se također koristi u situacijama kada nam je potreban duži životni vijek objekta
- Gomila može rasti kako se naš program mijenja
- Lokacija u RAM-u !!!
- Gomila se naziva dinamičkom memorijom zato što veličinu objekta zadajemo tek tijekom izvođenja



DINAMIČKA ALOKACIJA NA STOGU

- Ideja: alocirati memoriju na gomili je skupa operacija
 - Zašto ne na stacku :)
- Memorija se oslobađa nakon izlaska iz pozivajuće funkcije
 - Nema poziva funkcija alokatora npr. delete, free ili new
- Na Windowsima najviše 1MB, dok je na Linuxu moguće rezervirati do 8MB
 - To ovisi o funkcijama koje su se pozivale prije, moguće je da imamo i manje naravno
- Koriste se funkcije `_alloca` I `_malloc`
 - Bolje je koristiti `_malloc` jer će, ako nema dovoljno mesta na stogu, memorija biti rezervirana na gomili

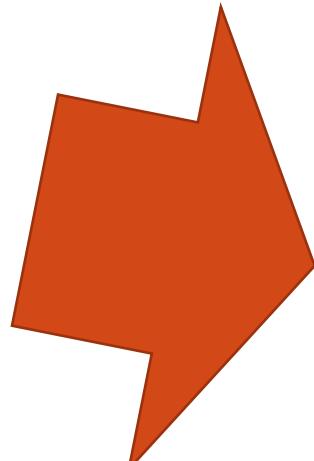
```
1 void allocStackDynamic(size_t size)
2 {
3     assert(size > 0);
4     char *mem = static_cast<char *>(_malloc(size));
5     memset(mem, 0, size);
6     _freea(mem);
7 }
```



KLJUČNA RIJEĆ NEW



- Interno se održava free lista -> koji su sve komadi memorije slobodni, gdje su, koliko zauzimaju i sl. -> kako?

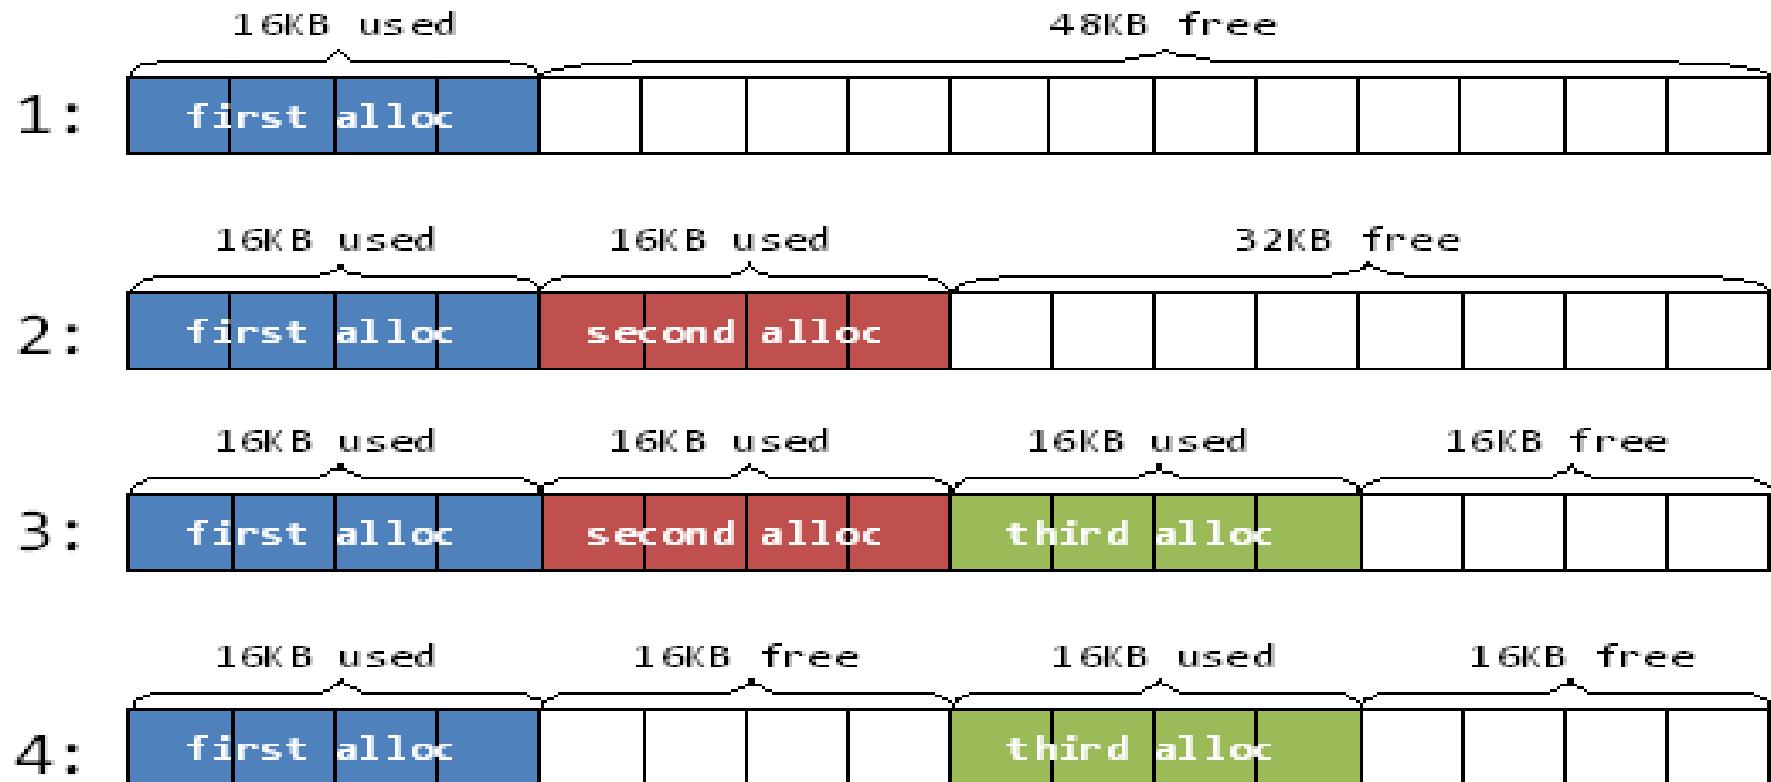


OS nam dodijeli određeni dio memorije prilikom započinjanja programa

New najčešće u pozadini koristi malloc, ali to ovisi o konkretnoj implementaciji STL-a(ne kompjeler ili OS)

Operacija koja je pogotovo skupa: treba mi još memorije!!!





MALLOC

- Zahtjevi dobrog memorijskog alokatora(malloc, realloc, free):

- **Kompatibilnost** s drugima, poštuje ANSI/POSIX konvencije
- **Portabilnost** -> što je manje moguće sistemski-ovisnih poziva
- Alokator bi trebao zauzimati memoriju na način da **minimizira fragmentaciju !!!**
- **Vrijeme izvođenja**
- Neke **opcije izvođenja** se mogu mijenjati - staticki pomoću #define, dinamički pomoću kontrolnih naredbi kao što je npr. mallopt
- Maksimiziranje prepoznavanja greške
- **Neovisnost** o vrsti programa koji se izvodi(GUI, kompjjeri, web programi, procesiranje stringova i sl.)

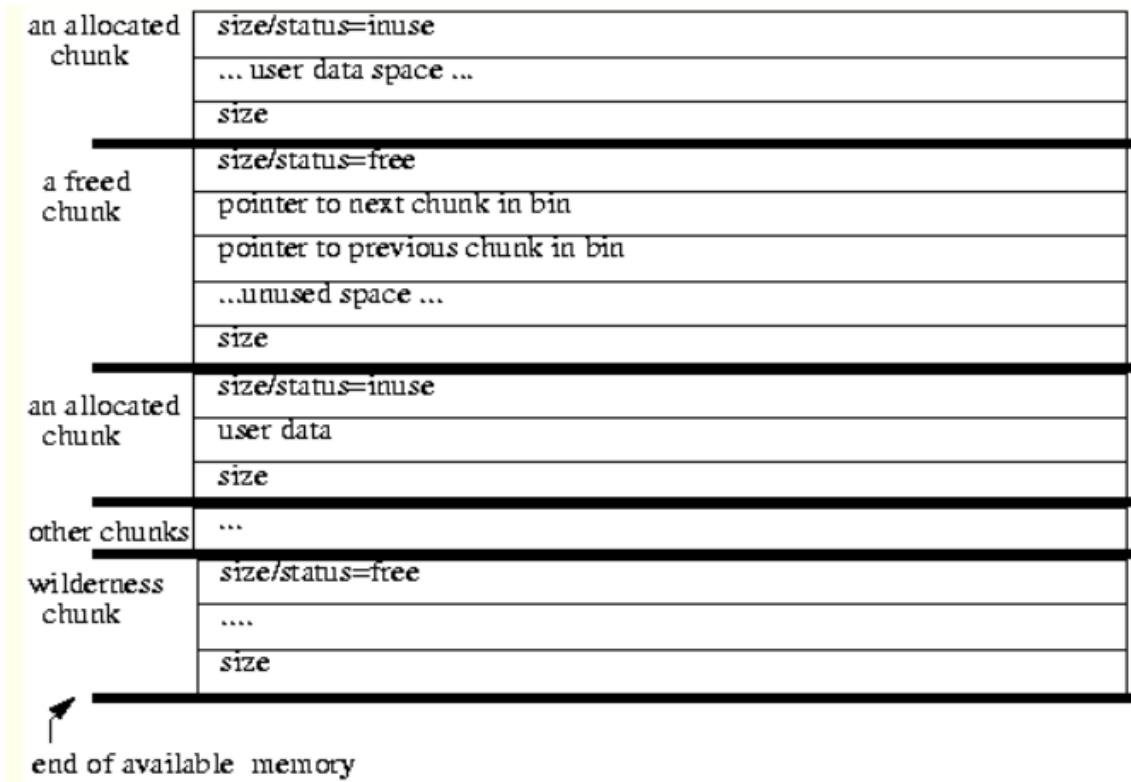
U teoriji vremenski najbrža inačica je ona koja alocira uvijek susjedni dio memorije, a implementacija za free je no-op. Na taj način imamo jako malo promašaja kod straničenja i keširanja, ali brzo dolazimo do situacije u kojoj više nemamo dostupne memorije.



ALGORITMI MALLOC-A

1. Granične oznake

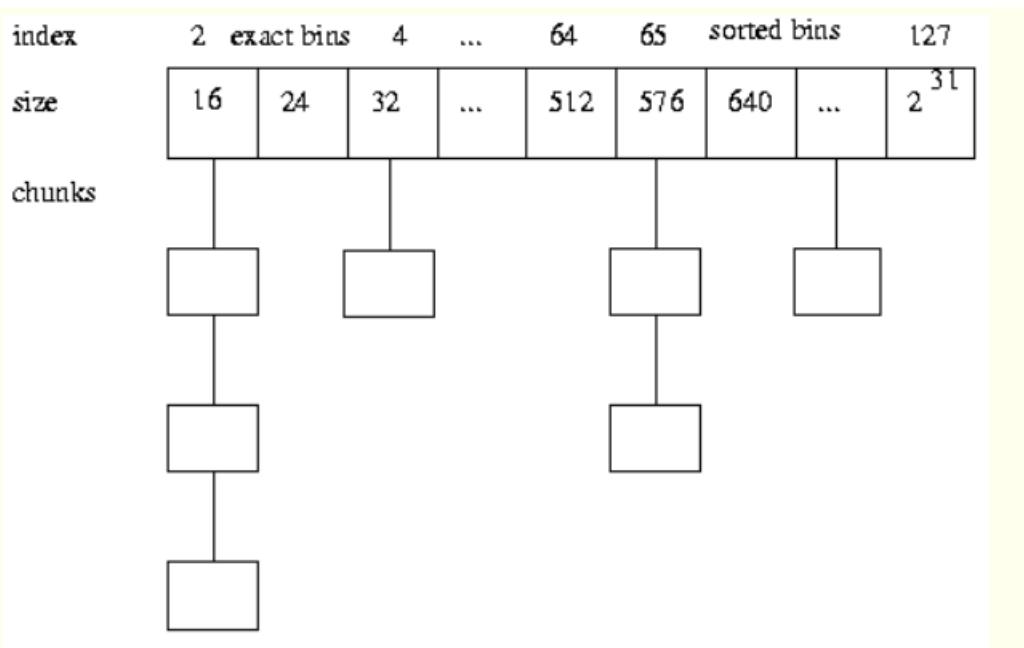
- Svaki komadić memorije(chunk) sadrži u sebi informacije o **veličini prijašnjeg i sljedećeg chunka**
-> time je olakšano spajanje više njih u jedan veći chunk
- Omogućena je pretraga **naprijed i nazad**
- Prvotne verzije su doslovno to koristile
- Poboljšanje: chunkovi koji su aktivni ne nose te informacije jer ih i ovako neće moći koristiti
= otežana detekcija grešaka, ali povećana efikasnost



ALGORITMI MALLOCA

2. Binning

- Dostupni chunkovi su organizirani u kontejnere(grupirani po veličini)
- Najmanji mogući chunk koji nam je dovoljan se traži -> best-fit search -> najmanja fragmentacija



Optimizacija na način da se chunkovi unutar kontejnera sortiraju.

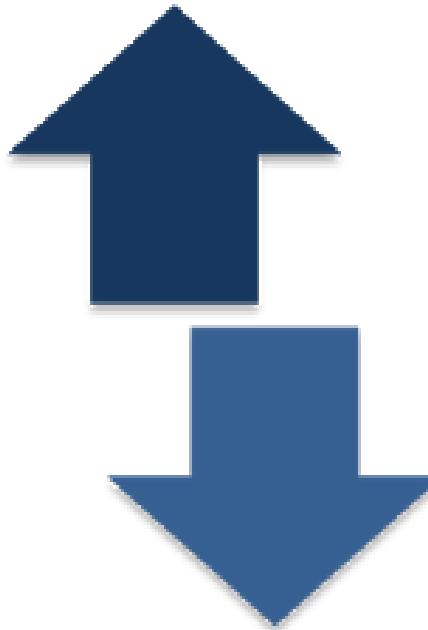
Zaključak:

Najbolji prvi sa spajanjem, oslobođeni se spajaju s a susjedima i drže u pripadnom sortiranom kontejneru



HEURISTIČKA POBOLJŠANJA ALOKATORA

1. Očuvanje lokalnosti
2. „Wilderness preservation”
3. Mapiranje memorije
4. Keširanje
5. „Lookasides”



**Heuristic techniques
are ideal as a quick fix**

but

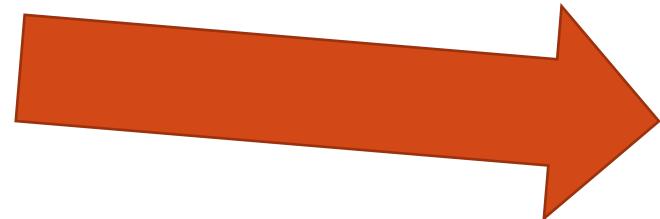
*can introduce error, bias &
may constrain creativity*

Heuristika omogućava
efikasnije korištenje
alokatora



OČUVANJE LOKALNOSTI

- Temelji se na pretpostavci da chunkovi memorije koji su alocirani u približno slično vrijeme imaju slična svojstva(slične reference, doseg...)
- Takva heuristika pokušava gotovo uvijek koristiti nearest-fit strategiju, upravo zbog pretpostavke lokalnosti



Fragmentacija

- Koristi se u situacijama kada stvara najmanje konflikata sa ostalim zahjevima alokatora



WILDERNESS PRESERVATION

- Predstavlja prostor koji graniči s najvišom adresom rezerviranim od sustava
- Jedini chunk memorije koji se može proizvoljno proširiti, naravno pod pretpostavkom da ima dostupne memorije

Koristimo na 2 načina



Tretiramo kao i ostale chunkove
Brzina, jednostavnost, ali moguće loše
memorijske karakteristike

Tretiramo chunk kao veći, nego što je
jer zapravo on takav može postati -> koristi
se samo onda kada drugi chunkovi ne postoje



LOOKASIDES

- U starijim verzijama minimalna veličina chunka je bila 16B pa je u situacijama u kojim je npr. neka struktura podataka koristila samo 8B(za jedan čvor) došlo do nepotrebnog gubljenja memorije
- New alokator bi mogao provjeravati adrese da li se koriste, kojem prostoru pripadaju i sl., ali to bi bilo neefikasno
- U tim situacijama programer bi mogao napisati svoj prilagođeni alokator
 - Novije verzije new alokatora te stvari imaju rješene, a implementiranje svojeg alokatora je u većini situacija nepotrebno



CACHING

- Najosnovnija verzija algoritma spaja susjedne chunkove, a odvaja ih samo kad je to nužno(skupe operacije!!!)
- 2 caching strategije:
 1. Nemoj spajati susjede, nego se nadaj da će ubrzo doći sljedeći zahtjev u kojem ćeš iskoristiti chunk te veličine(odgodjeno spajanje)
 2. Odvoji chunkove unaprijed i to više njih, a ne jedan po jedan(preallociranje)

Koristi se u situacijama kada se često stvaraju i otpuštaju chunkovi iste veličine, npr. struktura podataka. Koristi se samo za keširanje chunkova malih veličina. Moderni programi koriste klase različitih veličine pa teško profitiramo od ovoga.



PRILAGOĐENI ALOKATORI U C++

- Alokator je programski alat iz STL-a kojeg koristimo za upravljanje memorijom
- Alexander Stepanov želio proširiti STL, ciljevi:
 - Apstrahiranje pristupa različitim memorijama(shared memory, garbage collected memory) – danas strože, nego što je on to izvorno zamislio
 - Povećanje performanse programa
- Alokator new općenit alokator što znači da mora prekrivati sve slučajeve
 - Bolje radi za rijeđi pristup većim objektima kao što su vektori
 - Dobar primjer gdje se može postići povećanje performansi pisanjem prilagođenog alokatora je u programu koji često stvara i otpušta objekte male veličine
- Gotovo svim custom alokatorima je zajedničko da unaprijed rezerviraju određeni blok memorije
 - Konkretna implementacija onda određuje I mijenja pristup

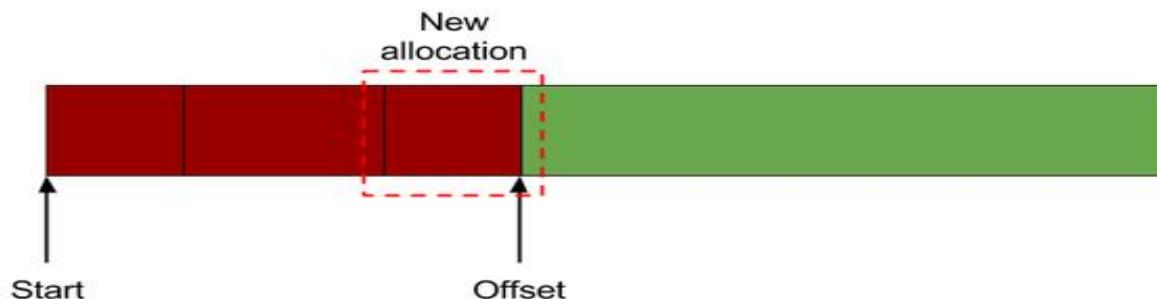


LINEARAN ALOKATOR

- Iznimno jednostavan, jedino što nam treba je pointer koji se pomiče kako rezerviramo memoriju
 - Free operacija skupa jer se odjednom oslobađa cijeli blok memorije, ne razlikujemo pojedini blok memorije od drugog

Allocate

Simply move the pointer (or offset) forward.



Complexity: $O(1)$

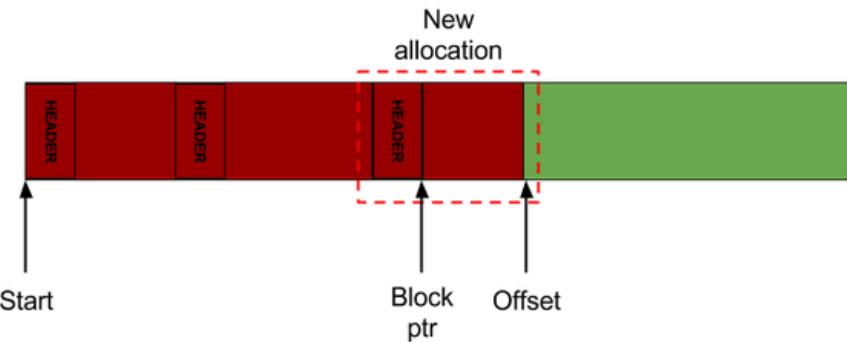


STOG ALOKATOR

- Unaprijeđenje linearog alokatora
- Pri alociranju pointer se pomiče prema naprijed, ali za razliku od linearog alokatora sada ne moramo dealocirati cijeli blok memorije odjedanput, nego pomičemo pointer unazad

Allocate

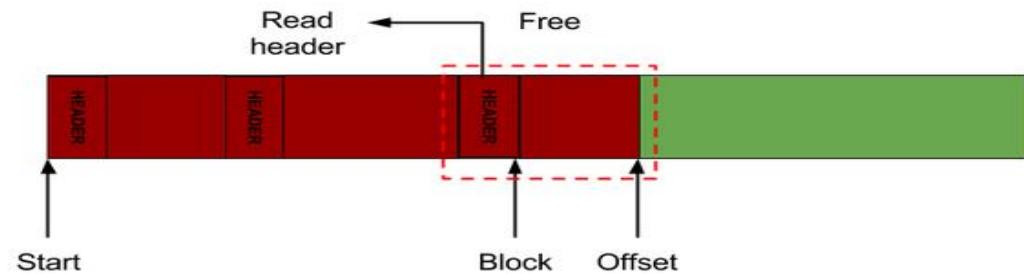
Simply move the pointer (or offset) forward and place a header right before the memory block indicating its size.



Complexity: $O(1)$

Free

Simply read the block size from the header and move the pointer backwards given that size.

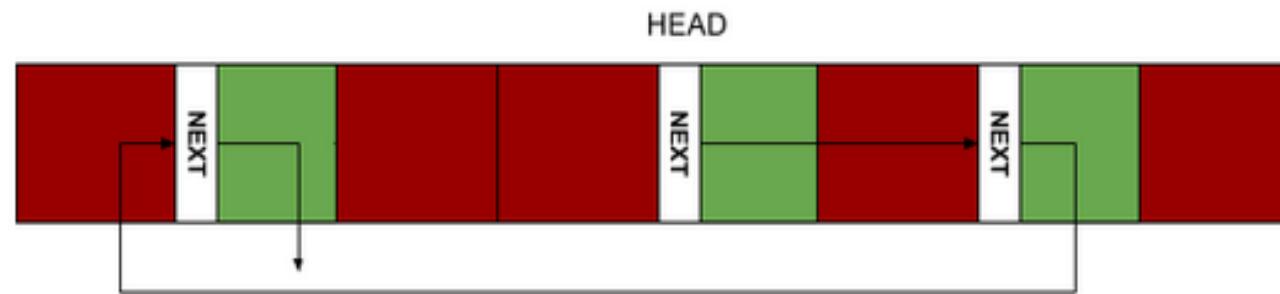
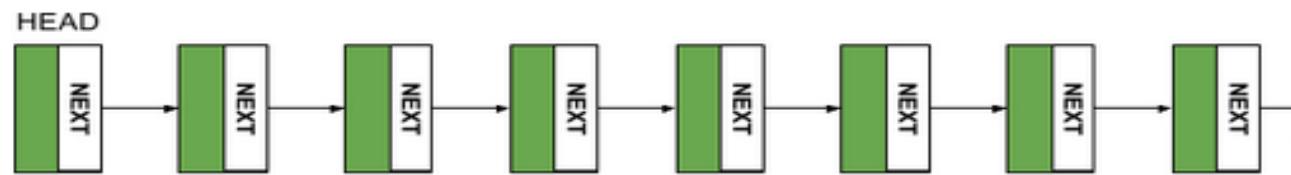
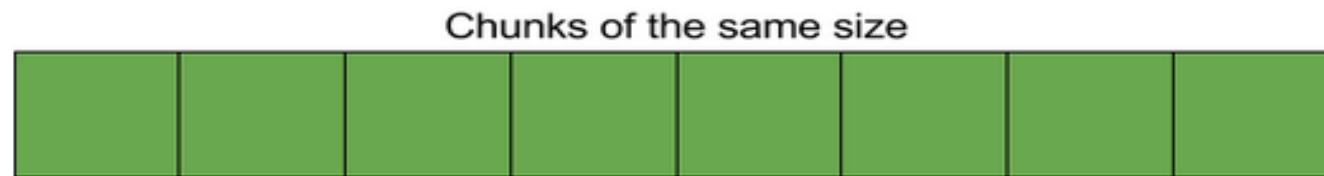


POOL ALOKATOR

- Rezervira unaprijed veći blok memorije te ga podijeli u manje dijelove iste veličine
- U svakom chunku je zapisan pokazivač na sljedeći slobodni blok memorije
 - Pazi: Ograničenje je onda da svaki chunk mora biti minimalno veličine čvora povezane liste u kojoj se pamte adrese na sljedeći slobodni blok memorije
- Alociranje: Uzmi prvi blok iz povezane liste
- Dealociranje: Oslobođeni blok stavi na prvo mjesto u povezanu listu
- Alociranje I dealociranje imaju konstantnu vremensku složenost, ali korištenje pool alokatora je u konačnosti linearno u vremenu zbog inicijalizacije jednostrukog povezane liste
- Pogodno kod korištenja objekata koji su uvijek iste veličine

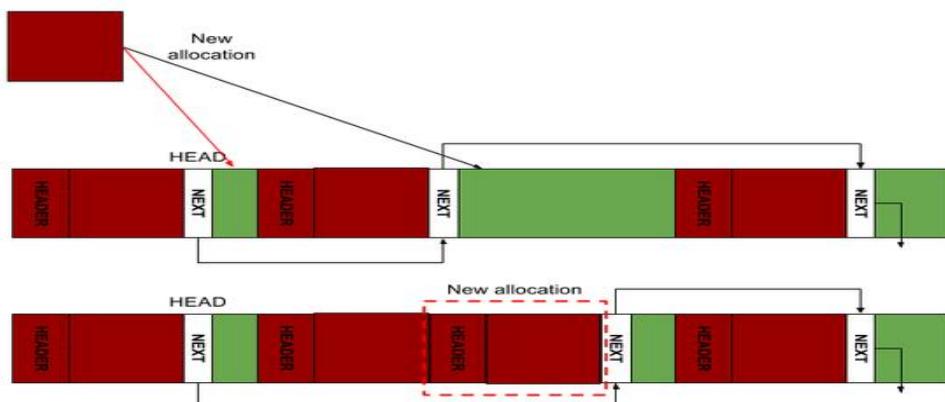


POOL ALOKATOR

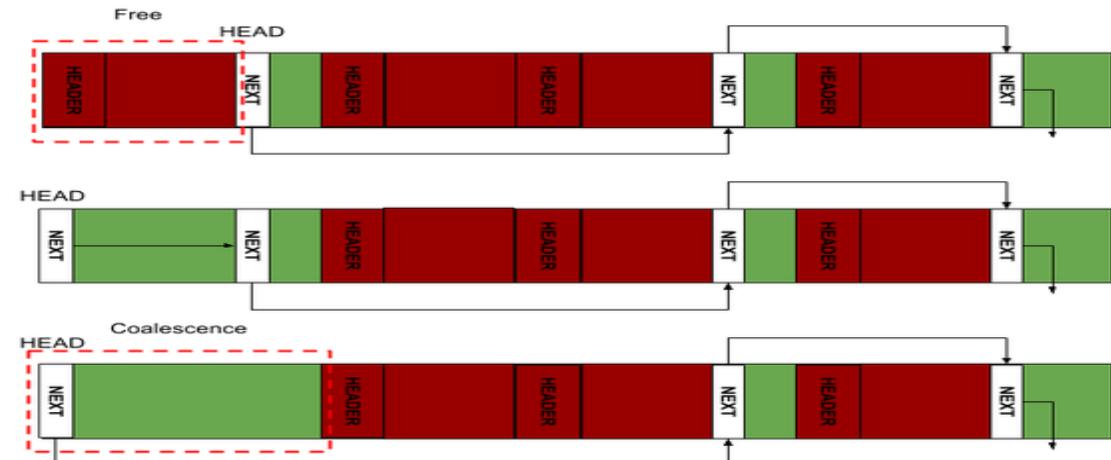


ALOKATOR – LINEARNA LISTA

- Svi prethodni alokatori stavlju ograničenja na pristup podatcima -
 - Slijedno – sa stalnim oslobađanjem ili bez – linearan I stogovni alokator
 - Svi objekti su iste veličine - pool alokator
- Alokator koji u pozadini koji koristi linearnu listu daje puno više slobode pri korištenju memorije
 - Pri tome imamo smanjenje performanse zbog toga jer obje operacije(alociranje I dealociranje) imaju linearnu vremensku složenost



Complexity: $O(N)$ where N is the number of free blocks



Complexity: $O(N)$ where N is the number of free blocks

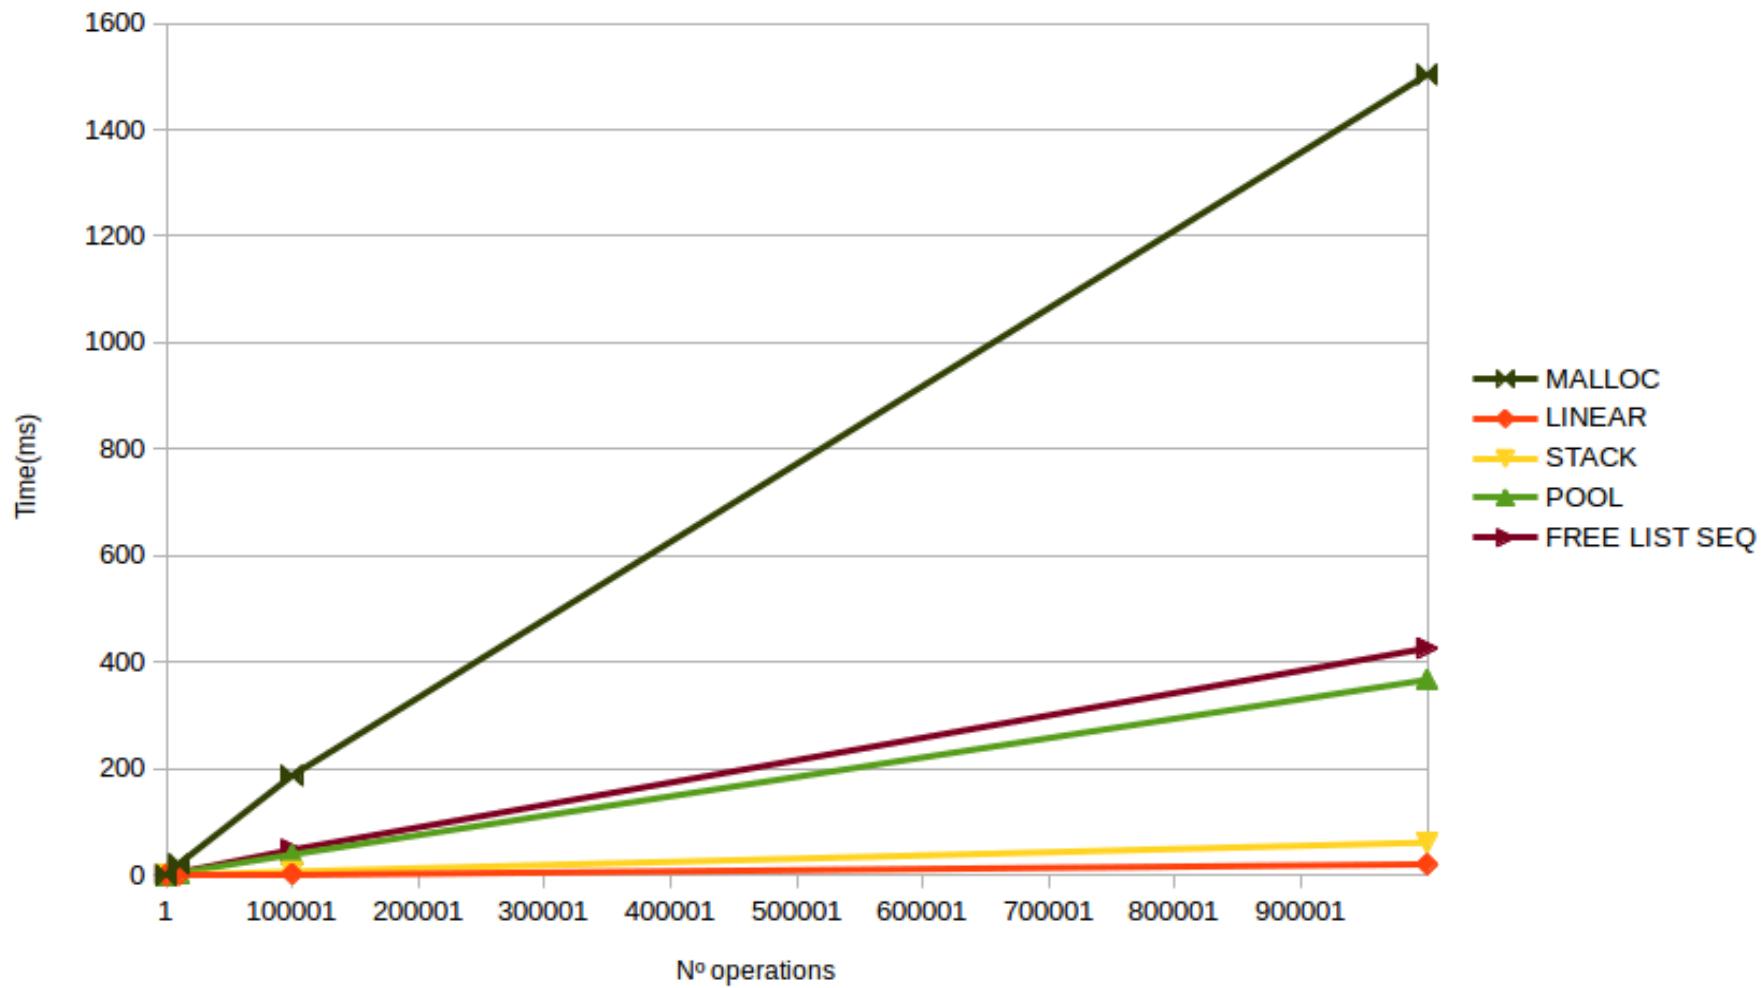


USPOREDBE ALOKATORA

- Malloc je najsporiji zbog svoje općenitosti
- Pool alokator, linearan I stogovni alokator su puno brži međutim zahtijevaju korištenje memorije u posebnom obliku
 - Linearni - ne dopušta oslobođanje malih dijelova memorije
 - Stogovni – sve operacije imaju konstantnu vremensku složenost, ali se memoriji mora pristupat na način da se koristi LIFO(Last-In-First-Out)
 - Pool alokator – zahtijeva da su svi dijelovi memorije koje koristimo iste veličine
- Alokator koji koristi u pozadini listu je najbolji izbor
 - Njega se može ubrzati koristeći stablo kao strukturu podataka pri čemu bismo imali sortirane dijelove memorije logaritamske vremenske složenosti



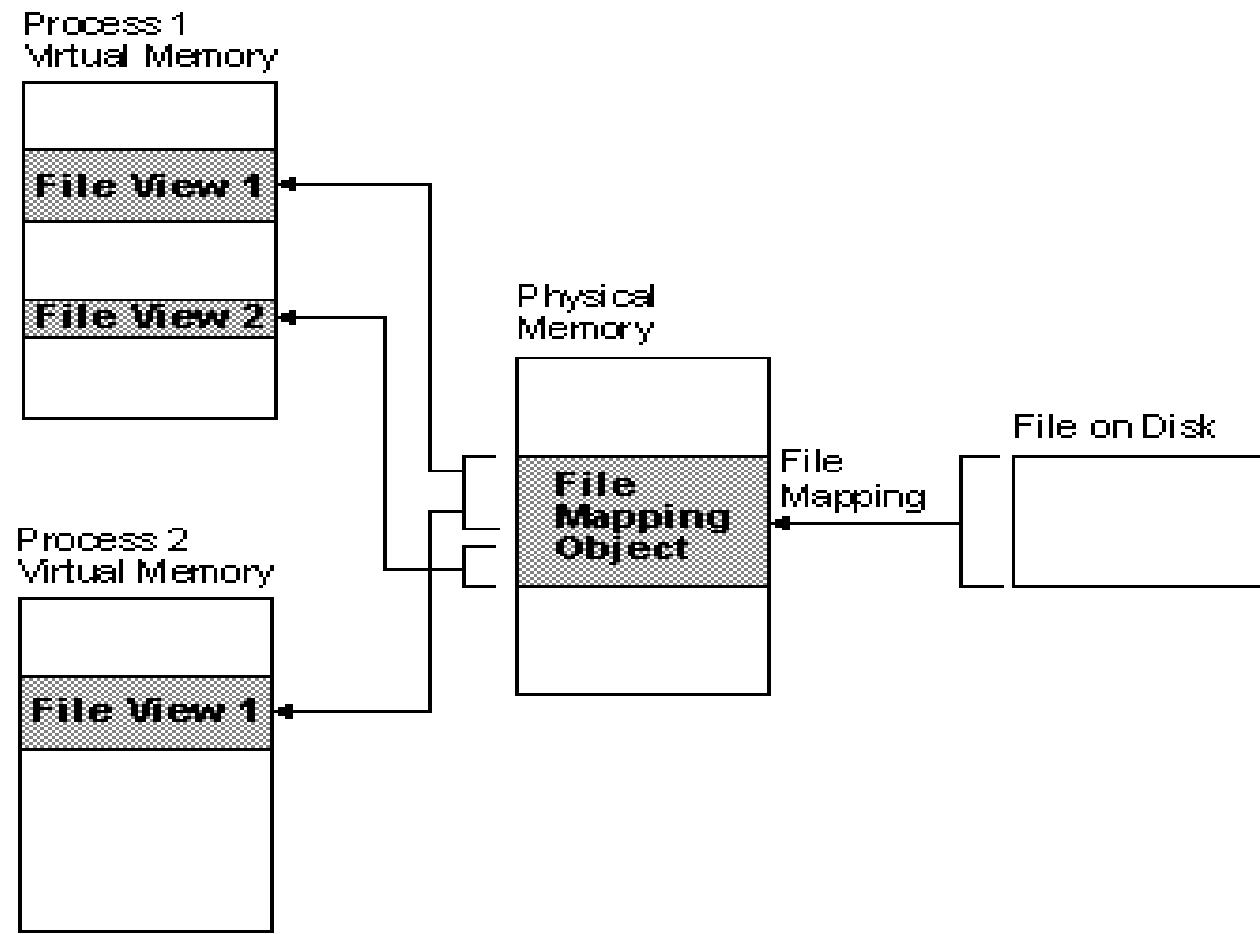
Time complexity of allocations/free (block size = 4096)



MEMORY MAPPING

- Virtualna memorija se brine za alociranje odvojenih prostora memorije programu
 - Najčešće mapiramo datoteku veće veličine
- Smanjuje fragmentaciju – ne stvaraju se rupe u memoriji
- Nakon mapiranja datoteci se pristupa kao memoriji što znači da se mogu koristiti mnogobrojni postupci za ubrzavanje pristupa sadržaju
 - Npr. compiler auto-vectorization, SIMD intrinsics, prefetching, optimized in-memory parsing routines, OpenMP
- Vrijedno koristiti samo u nekim situacijama:
 1. Više procesa koji dijele istu memoriju, mmap omogućava da svi ti procesi dijele istu memoriju
 2. Optimiziranje operacija straničenja
 - ako npr. A i B koriste istu memoriju, A preko buffera, i B preko mmap, ako se promijeni sadržaj memorije B će moći svejedno koristit tu memoriju jer će znati koje stranice su promijenile





POZITIVNE STRANE MAPIRANJA

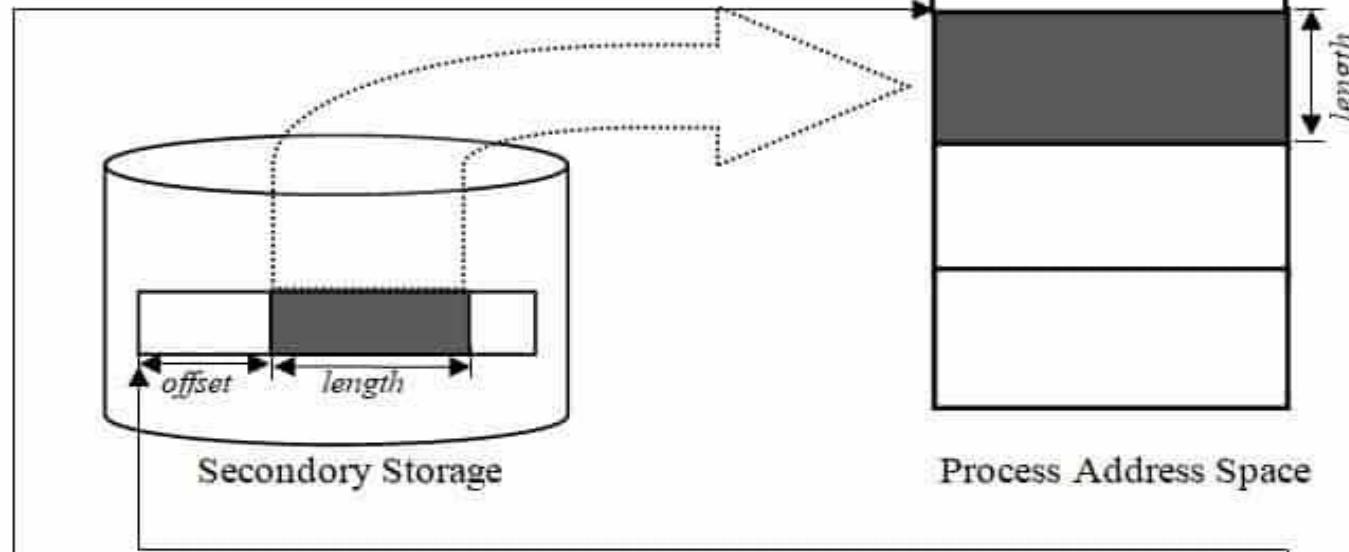
- Alternativa običnom čitanju
- Nasumičan pristup datoteci
- Koristimo istu datoteku više vremena(ne koristimo je samo jednom pri čitanju)
- Omogućava korištenje stranica iz keša I nakon zatvaranja I ponovnog otvaranja datoteke, s običnim čitanjem datoteka je već vjerojatno izbačena iz keša, zbog poziva flush()
- Dijeljenje memorije između procesa
 - Procesi koriste iste fizičke stranice
- Potreban je samo 1 sistemski poziv za mapirat cijelu datoteku
- Nakon toga, nema nikakvog više kopiranja iz jezgre prema korisniku



USPOREDBA S OBIČNIM ČITANJEM

- Da bi se npr. datoteka od 50GB mapirala, uz veličinu stranice od 4K, potrebno je 12.5 milijuna promašaja prilikom straničenja -> uz best-case scenario gdje je svaki promašaj ~100ns dolazimo do brojke od 1.25s
- Najveći je nedostatak običnog čitanja to što svaki poziv metode `read()` zahtijeva KOPIRANJE N bajtova iz jezgre prema korisniku
- Prema tome osnovna stvar koju se ovdje pitamo je:
 - Da li je veći trošak kopiranje bajtova iz jezgre ili posao koji moramo učiniti pri svakom promašaju kod straničenja
 - Odgovor ovisi o puno faktor:
 - `Copy_to_user` faktor kopiranja, hardverska potpora mapiranju, veličina TLB-a itd.





```
void *mmap (void *address, size_t length, int protect, int flags, int filedes, off_t offset)
```

access permission (PROT_READ, PROT_WRITE, PROT_EXEC)

nature of the map(MAP_SHARED, MAP_PRIVATE,
MAP_ANON, MAP_FIXED)



MEMORIJSKO MAPIRANJE U C++, LINUX

- 1. argument je željena adresa, jezgra bira najbližu moguću adresu, ako mu damo null onda jezgra sama nasumično odabere početnu adresu
- 2. broj bajtova koje trebamo rezervirati
- 3. razina prava – pisanje, čitanje, izvršavanje
- 4. argument - zastavice
 - Map shared – dijeljenje memorije s ostalim procesima, promjene se upisuju u datoteku
 - Map private – promjene neće biti upisane u datoteku
 - Map anonymous – anonimno mapiranje, prostor nije mapiran u datoteku, primitivni način za povećanje gomile
 - Map fixed – zahtijeva se eksplicitno korištenje prostora od dane adrese

Više informacija o memorijskom mapiranju na Windowsima

<https://docs.microsoft.com/en-us/windows/win32/memory/file-mapping>



MMAP IN C++

The screenshot shows a Linux desktop environment with a terminal window and a code editor.

The terminal window at the bottom left shows the command:

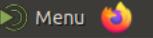
```
[andi@ubuntu: ~/Com...]
```

The code editor (GNOME Code Editor) shows the file `Mmap.cpp` with the following content:

```
1 #include <algorithm>
2 #include <iostream>
3 #include <cstring>
4 #include "../IO/Timer.h"
5 #include <sys/mman.h>
6 #include <sys/stat.h>
7 #include <fcntl.h>
8
9 const char* mapFile(const char* fileName, int& length)
10 {
11     int fd = open(fileName, O_RDONLY);
12     if (fd == -1) {
13         std::cout << "Cannot open file!" << std::endl;
14         exit(-1);
15     }
16     // obtain file size
17     struct stat statbuffer;
18     if (fstat(fd, &statbuffer) == -1) {
19         std::cout << "Cannot obtain file size!" << std::endl;
20     }
21
22     length = statbuffer.st_size;
23
24     const char* addr = static_cast<const char*>(mmap(NULL, length, PROT_READ, MAP_PRIVATE, fd, 0u));
25     if (addr == MAP_FAILED) {
26         std::cout << "Cannot map file!" << std::endl;
27     }
28
29     //munmap((char*)addr, length);
30
31     return addr;
32 }
33
34
35 int main()
36 {
37     Timer timer;
38     int length;
39     auto startingPointer = mapFile("../1GB.in", length);
40     auto endingPointer = startingPointer + length;
41
42     int lines = 0;
43     while (startingPointer && startingPointer!=endingPointer)
44         if ((startingPointer = static_cast<const char*>(memchr(startingPointer, '\n', endingPointer-startingPointer)))) {
45             lines++;
46             startingPointer++;
47         }
48
49     std::cout << "Lines: " << lines << std::endl;
50 }
51 }
```

The status bar at the bottom right shows:

Ln 14, Col 5 SPACES LF C++ UTF-8



● andi@ubuntu: ~/ComputerArchitecture/Mmap/Build

File Edit View Search Terminal Help

```
andi@ubuntu:~/ComputerArchitecture/Mmap/Build$ ./Mmap
lines: 4195037
timer took 158.489 ms
andi@ubuntu:~/ComputerArchitecture/Mmap/Build$ 
```

HR intel Bluetooth (100%) Mon Nov 30, 22:02

andi@ubuntu: ~/Comp... [andi@ubuntu: ~/Com... [andi@ubuntu: ~]

performance - Fast tex... /home/andi/Computer... [Mmap]

andi@ubuntu: ~/Comp...

[]

NORMALNO ČITANJE IZ DATOTEKE

```
1 #include <iostream>
2 #include <fstream>
3 #include "../IO/Timer.h"
4
5 //reads one 1GB file with ifstream
6 // to create 1GB file run dd if=/dev/urandom of=file.txt bs=1048576 count=1024
7 void readFile() {
8     std::ifstream input;
9     input.open("../1GB.in");
10    if(!input) {
11        std::cout << "Cannot open file" << std::endl;
12        return;
13    }
14    std::string line;
15    int lines = 0;
16    while(getline(input, line)) {
17        lines++;
18    }
19    std::cout << "Lines: " << lines << std::endl;
20 }
21
22
23 int main() {
24     Timer timer;
25     readFile();
26 }
27 }
```

USPOREDBA

- Duplo brže se izvodi program koji koristi memorijsko mapiranje datoteke veličine 1GB

A screenshot of an Ubuntu desktop environment. At the top, there is a dark grey header bar with various icons for system status and user information. Below this is a terminal window with a dark background and light-colored text. The terminal shows the command `./FilesReading` being run, which reads a file and prints the number of lines (4195038) and the timer took (365.517 ms). The bottom of the screen features a dock with several application icons, including a browser, file manager, terminal, and system monitor.

```
Menu 🌐
● andi@ubuntu: ~/ComputerArchitecture/FilesIO/build
File Edit View Search Terminal Help
andi@ubuntu:~/ComputerArchitecture/FilesIO/build$ ./FilesReading
Lines: 4195038
Timer took 365.517 ms
andi@ubuntu:~/ComputerArchitecture/FilesIO/build$
```

BINARNI UI

- Razmislimo o jednom čestom načinu korištenja dva programa:
 1. Prvi program stvara strukturu podataka i zapisuje u datoteku
 2. Drugi program čita podatke iz datoteke i koristi ih

2 načina implementacije, prvo pomoću zapisivanja teksta u odredišnu datoteku, a drugi način je zapisivanje u binarnu datoteku.

Za procjenu rezultata koristili smo datoteku veličine 81MB koju smo zapisivali i čitali najprije u txt datoteku, a onda u .dat datoteku.

Pogledajmo rezultate ☺



```
#include <unordered_map>
#include <iostream>
#include <string>
#include "../IO/Timer.h"
#include <fstream>

#define NUM_ACTIONS 10000000

//Simulations of typical use, we create some object in file and then need to pass it to other file when this process ends. That's the reason why we
//are allocating space on heap two times when we could actually only once. WE SIMULATE STORING IN THIS FILE AND READING FROM ANOTHER FILE.
//enum needs bytes accordingly to information that stores. For example size of ActionType is 4bits bytes

enum ActionType {PAST, PRESENT, FUTURE};

std::unordered_map<std::string, enum ActionType> conversion_table;

//we only care about performance not about data
class Action {
public:
    std::string actionPerformed;
    ActionType actionType;
    int actionIndex;

    Action() {
        actionPerformed = "RandomName";
        actionType = PRESENT;
        actionIndex = 1;
    }

    void printAction() {
        std::cout << actionPerformed << " " << actionType << " " << actionIndex << std::endl;
    }
}
```



```
~Action() {

}

};

Action* createActions() {
    Action* actions= new Action[NUM_ACTIONS];
    return actions;
}

//neglect reserving on heap and deleting objects from heap
void storeActionsAsText() {
    Action* actions = createActions();
    std::ofstream stream("Actions.txt");
    for(int i = 0; i < NUM_ACTIONS; i++) {
        stream << actions[i].actionName << " " << actions[i].actionType << " " << actions[i].actionIndex << std::endl;
    }
    delete[] actions;
}

//neglect reserving on heap and deleting objects from heap
void readActionsFromText() {
    std::ifstream stream("../Action.txt");
    Action* actions = createActions();
    for(int i = 0; i< NUM_ACTIONS; i++) {
        std::string enumName;
        stream >> actions[i].actionName;
        stream >> enumName;
        actions[i].actionType = conversion_table[enumName];
        stream >> actions[i].actionIndex;
    }
    delete[] actions;
}
```



```
void simulateText() {
    Timer timer;
    storeActionsAsText();
    readActionsFromText();
}

void storeActionsAsBinary() {
    Action* actions = createActions();
    std::ofstream wb("../actions.dat", std::ios::out | std::ios::binary);
    if(!wb) {
        std::cout << "Cannot open file for writing" << std::endl;
        return;
    }
    for(int i = 0; i < NUM_ACTIONS; i++) {
        wb.write((char*) &actions[i], sizeof(Action));
    }
    wb.close();
    if(!wb.good()) {
        std::cout << "Error occurred while writing to file" << std::endl;
        return;
    }
    delete[] actions;
}

void readActionsAsBinary() {
    Action* actions = createActions();
    std::ifstream rf("../actions.dat", std::ios::out | std::ios::binary);
    if(!rf) {
        std::cout << "Cannot open file for reading!" << std::endl;
        return;
    }
    for(int i = 0; i < NUM_ACTIONS; i++) {
        rf.read((char*) &actions[i], sizeof(Action));
    }
    rf.close();
}
```

```
if(!rf.good()) {  
    std::cout << "Error occurred at reading time!" << std::endl;  
    return;  
}  
delete[] actions;  
}
```

```
void simulateBinary() {  
    Timer timer;  
    storeActionsAsBinary();  
    readActionsAsBinary();  
}
```

```
int main() {  
    conversion_table["PAST"] = ActionType::PAST;  
    conversion_table["PRESENT"] = ActionType::PRESENT;  
    conversion_table["FUTURE"] = ActionType::FUTURE;  
    std::cout << "Text simulation: " << std::endl;  
    simulateText();  
    std::cout << std::endl << "Binary simulation: " << std::endl;  
    simulateBinary();  
}
```



BINARNI UI: ZAKLJUČAK

- Brži način zapisivanja podataka u bajtovima
 - Npr. Txt datoteka će za broj 12345 koristiti 5 bajtova, a binarna samo 2
 - Konačna binarna datoteka je puno manja, nego tekstualna pa je zato I takav način puno efikasniji
- Txt datoteka je čitljiva ljudima, a binarne datoteke ne
- Binarni UI je teže implementirati I koristiti, za datoteke relativno male veličine nemamo toliku dobit
- Biblioteke kao što su Boost nam mogu pomoći u tome
- Kod deserijalizacije treba paziti na "endianess"



SERIJALIZACIJA I PROTOCOL BUFFER

- Google ih je razvio
 - Amazon -> Ion
 - Facebook - >Apache Thrift
- Metoda serijaliziranja struktura podataka
 - Ideja: jednostavno, sigurno, brzo I lako mrežno komuniciranje
 - Machine readable
 - ASCII format serijalizacije
 - Može se koristiti I za spremanje podataka
 - Ideja: strukture podataka = poruke su opisane u .proto datoteci
 - Ta se datoteka prevađa sa protoc kompjlerom
 - Prevedeni kod onda koriste hipotetski pošiljatelj I primatelj



PROTOCOL BUFFER

```
// polyline.proto
syntax = "proto2";

message Point {
    required int32 x = 1;
    required int32 y = 2;
    optional string label = 3;
}

message Line {
    required Point start = 1;
    required Point end = 2;
    optional string label = 3;
}

message Polyline {
    repeated Point point = 1;
    optional string label = 2;
}
```

```
// polyline.cpp
#include "polyline.pb.h" // generated by calling "protoc polyline.proto"

Line* createNewLine(const std::string& name) {
    // create a line from (10, 20) to (30, 40)
    Line* line = new Line;
    line->mutable_start()->set_x(10);
    line->mutable_start()->set_y(20);
    line->mutable_end()->set_x(30);
    line->mutable_end()->set_y(40);
    line->set_label(name);
    return line;
}

Polyline* createNewPolyline() {
    // create a polyline with points at (10,10) and (20,20)
    Polyline* polyline = new Polyline;
    Point* point1 = polyline->add_point();
    point1->set_x(10);
    point1->set_y(10);
    Point* point2 = polyline->add_point();
    point2->set_x(20);
    point2->set_y(20);
    return polyline;
}
```



ZAVRŠNO O IO OPERACIJAMA

- Napomenimo za kraj kako korištenje '\n' u odnosu na std::endl također ubrzava izvođenje
 - Prvi svakom pozivu std::endl napravi se i flush stream-a
- Scanf i printf su brži od cin i cout, ali možemo jednako brzo čitati sa cin i cout uz pomoć ove dvije naredbe u main funkciji
- `ios_base::sync_with_stdio(false); cin.tie(NULL);`
 - uz using namespace std ;)



LITERATURA

- <https://docs.microsoft.com/en-us/windows-hardware/drivers/debugger/x64-architecture#:~:text=The%20x64%20architecture%20is%20a,sets%20are%20close%20to%20identical>
- <http://gee.cs.oswego.edu/dl/html/malloc.html>
- <https://www.youtube.com/watch?v=wJ1L2nSIV1s&list=PLlrATfBNZ98dudnM48yfGUldqGD0S4FFb&index=54>
- [https://linuxhint.com/using mmap function linux/](https://linuxhint.com/using_mmap_function_linux/)
- https://en.wikipedia.org/wiki/Protocol_Buffers
- http://www.tutorialspoint.com/C_Programming-Tutorial/27_C-File-IO-Handling.aspx
- [https://en.wikipedia.org/wiki/Allocator_\(C%2B%2B\)#Custom allocators](https://en.wikipedia.org/wiki/Allocator_(C%2B%2B)#Custom allocators)
- <https://geidav.wordpress.com/2013/03/21/anatomy-of-dynamic-stack-allocations/>
- <https://www.cs.swarthmore.edu/~newhall/cs31/resources/addrleal.php>
- <https://sourceware.org/binutils/docs/as/P2align.html#P2align>
- <https://www.techspot.com/article/2166-mmx-sse-avx-explained/>
- <https://www.cs.virginia.edu/~evans/cs216/guides/x86.html>
- <https://www.rapidtables.com/code/linux/gcc/gcc-o.html>



KRAJ

- <https://github.com/as51340/Memory-management-in-C>

Andi Škrgat

Mentor: profesor Siniša Šegvić

