

Generative Adversarial Networks

Doc.dr.sc. Marko Subašić

GANs


- Primarna namjena je generiranje uzoraka
- Ne procjenjujemo $p(\mathbf{x})$
- Ne traži uzorkovanje
 - Kod VAE smo aproksimativno uzeli jedan uzorak od \mathbf{z} iako smo trebali uzeti više njih
- Asimptotski konzistentan za razliku od VAE
- Često generira vizualno najbolje uzorke
 - Nije jasno zbog čega

Osnovna ideja

- Dvije mreže:
 - 1) Generator (G): generira umjetne uzorke
 - 2) Diskriminator (D): pokušava otkriti umjetne uzorke
- Dvije mreže su protivnici (adversaries)
 - Jedna pokušava prevariti drugu
 - Druga pokušava detektirati prevaru
 - Njihovo natjecanje tjera ih da budu sve bolji i bolji u svojim nastojanjima
 - U konačnici generator generira "savršene" umjetne uzorke koje diskriminator ne može razlikovati od pravih uzoraka


Osnovna ideja

- Dvostruka povratna veza
 - Diskriminator sa uzorcima iz skupa za treniranje
 - Generator sa diskriminatorom
- Može dovesti do nestabilnosti



Generator

- Želimo da slučajno generira različite uvjerljive uzorke
 - Da bi to postigli, negdje u mreži treba biti ugrađena "slučajnost"
 - Ulaz (z) će biti slučajni šum s nekom odabranom distribucijom $p(z)$
 - Ne pokušavamo pronaći $p(z|x)$ – jednostavnost!
 - Generator mora biti diferencijabilan



Diskriminator

- Treniran da bi razlikovao stvarne uzorke iz skupa za treniranje od umjetnih uzoraka koje proizvodi generator
 - Binarna klasifikacija
 - Klasa skupa za treniranje $y=1$, klasa umjetnih uzoraka $y=0$
 - Klasifikacija $p(y=1|x)$
 - Učenje pod nadzorom
 - On je pomoćni alat za poboljšanje generatora
 - Može se odbaciti, ali i ne mora...



Funkcija cilja

- Generator $G(z; \theta_g)$
 - θ_g su parametri generatora
 - Mapira ulazni prostor skrivene varijable z u prostor podataka
- Diskriminator $D(x; \theta_d)$
 - θ_d su parametri diskriminatora
 - Skalarna funkcija podataka koja procjenjuje vjerojatnost da ulazni podatak nije umjetno generiran

Funkcija cilja

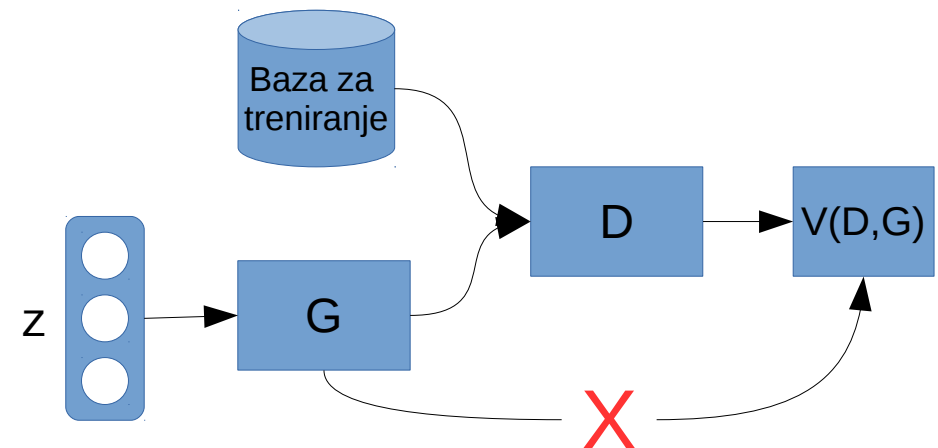
- Treniranjem se optimizara funkcija cilja s obzirom na parametre obje mreže

$$\min_G \max_D V(D, G) = E_{\mathbf{x} \sim p_{data}(\mathbf{x})} [\log D(\mathbf{x})] + E_{\mathbf{z} \sim p_z(\mathbf{z})} [\log (1 - D(G(\mathbf{z})))]$$

Procijenjena log vjerojatnost da je stvarni uzorci nisu umjetni

Procijenjena log vjerojatnost da generirani podaci jesu umjetni

- Minimax igra
 - Dvije mreže su suprotstavljene
 - Traži se ekvilibrij igre u sedlu – Nash-ev ekvilibrij



Što možemo reći da GAN radi

1) Automatizira testiranje i poboljšanje generatora

- Bitno pitanje kod generativnih modela je kako ocijeniti kvalitetu novih generiranih uzoraka
 - Nema ih se sa čime usporediti
- Diskriminator pokušava pronaći razlike između stvarnih slika i novih generiranih slika
 - Učenje pod nadzorom
 - Ako je uspješan (bolji od slučajnog odabira), onda generator ima mjesta za poboljšanje

Što možemo reći da GAN radi

2) Adaptivno treniranje

- Kako generator postaje sve bolji, diskriminator se tome prilagođava i pronalazi nove greške (razlika) koje generator radi
- Kako diskriminator postaje sve bolji, generator pronalazi nove načine da ga prevvari

Što možemo reći da GAN radi

3) Minimizira divergenciju

- Treniranje GAN-a je ekvivalentno minimizaciji Jensen-Shannonove divergencije

Koko se trenira GAN?

- Nije zadano...
- Zašto ne backprop?
- Funkcija cilja se lako evaluira

$$V(D, G) = E_{\mathbf{x} \sim p_{data}(\mathbf{x})} [\log D(\mathbf{x})] + E_{\mathbf{z} \sim p_z(\mathbf{z})} [\log (1 - D(G(\mathbf{z})))]$$

- Naizmjenično treniranje generatora i diskriminatora

Treniranje

- Osvježavanje parametara obje mreže

$$\theta_g^{t+1} = \theta_g^t + \eta \nabla_{\theta_g} V(\theta_g, \theta_d)$$

$$\theta_d^{t+1} = \theta_d^t - \eta \nabla_{\theta_d} V(\theta_g, \theta_d)$$

Algoritam treniranja

for broj iteracija **do**

for k koraka **do**

Uzmi mini grupu od m uzoraka z iz distribucije $p_g(z)$

Uzmi mini grupu od m uzoraka x iz distribucije $p_{\text{data}}(x)$

Osvježi diskriminator prema

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m [\log D(x^{(i)}) + \log(1 - D(G(z^{(i)})))]$$

Uzmi mini grupu od m uzoraka z iz distribucije $p_g(z)$

Osvježi generator prema

$$-\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^{(i)})))$$

Konvergenција

- Što je optimalni diskriminator?

$$\begin{aligned} V(G, D) &= \int_x p_{data}(x) \log(D(x)) dx + \int_z p_z(z) \log(1 - D(G(z))) dz \\ &= \int_x p_{data}(x) \log(D(x)) + p_g(x) \log(1 - D(x)) dx \\ &\leq \int_x \max_y [p_{data}(x) \log(y) + p_g(x) \log(1 - y)] dx \end{aligned}$$

$$f(y) = a \log y + b \log(1 - y)$$

$$f'(y) = 0 \rightarrow \frac{a}{y} - \frac{b}{1 - y} = 0 \rightarrow y = \frac{a}{a + b}$$

$$D_G = \frac{p_{data}}{p_{data} + p_g}$$

Konvergenција

- Što je optimalni diskriminator uz optimalni generator?

$$p_{data} = p_g \rightarrow D_G^* = \frac{p_{data}}{p_{data} + p_g} = \frac{1}{2}$$

- Daje 1/2 za sve uzorke bez obzira odakle dolaze

Konvergenција

- A koji bi bio optimalni generator?

$$\min_G \max_D V(D_G^*, G) = C(G) = E_{x \sim p_{data}(x)} \left[\log \frac{p_{data}}{p_{data} + p_g} \right] + E_{x \sim p_g(x)} \left[\log \frac{p_g}{p_{data} + p_g} \right]$$

$$C(G) = -\log 4 + KL(p_{data} | \frac{p_{data} + p_g}{2}) + KL(p_g | \frac{p_{data} + p_g}{2})$$


- KL divergencija je uvijek pozitivna

$$C(G) = -\log 4 + 2 JDS(p_{data} | p_g)$$

- Jensen-Shannon divergencija
 - jednaka 0 samo kada je $p_{data} = p_g$

Konvergencija

- Uz dovoljne kapacitete D i G
 - D će konvergirati u svoj optimum D_G^* za zadani G
 - D pokušava procijeniti omjer vjerojatnosti pomoću učenja pod nadzorom
 - G primiće p_g prema p_{data}
 - Izbor generatora ograničava p_g
 - Za višeslojni perceptron sve dobro funkcionira



Intuitivno

- Da bi generator bio dobar
 - Diskriminator mora biti približno idealan
 - Diskriminator je obično složeniji

Što je problematično

- Nejasan kriterij zaustavljanja
- Istovremeno slijeđenje gradijenta dviju mreža može dovesti do oscilacija ili nestabilnosti
 - Nemogućnost konvergencije
- Nema eksplicitne reprezentacije $p_g(x)$
- Teška usporedba s drugim generativnim modelima

Što je problematično

- Treniranje može dovesti do pamćenja uzoraka iz skupa za treniranje
- Teško je generirati skrivene varijable z iz ulaznih uzoraka x
- Mode collapse – generiranje uvijek iste slike
 - Nije uvijek identična, ali vrlo slična
 - Postoje razlike ali su male

Razlika u odnosu na VAE

- VAE indirektno optimizira funkciju cilja $p(x)$
- GAN direktno minimizira funkciju cilja
 - Diskriminator određuje/uči funkciju cilja


Neke varijacije

- Kako bi se izbjegli problemi GAN mreža

Varijacija funkcije cilja za G

- Nema garancija da će paralelni backpropagation konvergirati
- Postoje razni heuristički trikovi
- Modifikacija cilja kako bi se izbjeglo prerano zasićenje gradijenata ako je G loš

$$-\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(\mathbf{z}^{(i)}))) \quad \longrightarrow \quad \nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log(D(G(\mathbf{z}^{(i)})))$$



Feature matching

- Može pomoći gdje je obični GAN nestabilan
- Dodatni član funkcije cilja generatora kojim se želi postići podudarnost značajki
 - Značajkama se proglašavaju vrijednosti jednog skrivenog sloja diskriminatora - $\mathbf{f}(\mathbf{x})$

$$\left\| E_{\mathbf{x} \sim p_{data}(\mathbf{x})} \mathbf{f}(\mathbf{x}) - E_{\mathbf{z} \sim p_z(\mathbf{z})} \mathbf{f}(G(\mathbf{z})) \right\|$$

- Ideja ima smisla zato što diskriminator ima za cilj pronaći bitne značajke za razlikovanje stvarnih od umjetnih uzoraka
- Daje dobre rezultate ako se želi dobiti jači klasifikator

Minibatch discrimination

- Odgovor na mode collapse
- Ugradnja dodatnog mehanizma u diskriminator kako bi mogao detektirati mode collapse
 - Promatranje cijelog minibatch-a
 - Neki skriveni sloj diskriminatora $f(\mathbf{x})$ se proširuje određenim brojem mjera varijacije unutar minibatch-a
 - Minibatch-evi koje proizvodi generator moraju oponašati varijabilnost minibatch-eva za treniranje
 - Mjere varijacije uzoraka se isto treniraju
- Daje dobre rezultate ako se teži generiranju vizualno uvjerljivi uzoraka
 - Bolje od feature matchinga

Povijesno usrednjavanje

- G i D imaju dodatni član funkcije cijene

$$\left\| \theta - \frac{1}{t} \sum_{i=1}^t \theta[i] \right\|^2$$

- $\theta[i]$ su parametri u prthodnom trenutku i
- Kažnjava se velika odstupanja težina od povijesne srednje vrijednosti
- Inspiriran rješenjima iz teorije igara
- Može pomoći kod nekonveksnih problema

Reference batch normalization

- Batch normalization dovodi od ovisnosti izlaza za x o ostalim uzorcima u minibatch-u
- Uvodi se referentni minibatch koji služi za normalizaciju svih minibatch-eva
 - Određuje se samo jednom
- Podrazumijeva unaprijedni prolaz kroz mrežu za trenutni minibatch i za referentni minibatch

Virtual batch normalization

- Odabere se reference batch
- Svaki element x trenutnog minibatcha se normalizira pomoću novog minibatcha koji se sastoji od x i od reference batcha

Semi supervised learning

- Izlaz D se proširuje za predikciju K klasa (K+1 izlaz)
- Diskriminator tada optimizira dvije funkcije cijene
 - Uobičajeni GAN gubitak – stvarni ili umjetni uzorak
 - Gubitak učenja pod nadzorom – procjena klase uzorka kao je ulazni uzorak iz skupa za treniranje i ako je označen
- Korištenje Feature matchinga donosi bolje rezultate za semi-supervised klasifikaciju
- Semi-supervised učenje omogućuje veću kvalitetu generiranih slika
 - Pretpostavka je da oznaka klase nosi statistiku koja je bitna za ljudsku interpretaciju

One-sided label smoothing

- Poznata metoda regularizacije

$$D_G = \frac{\alpha p_{data} + \beta p_g}{p_{data} + p_g}$$

- Cilj za pozitivnu klasifikaciju se postavlja na α (npr. 0.9) ,
a negativnu na β (npr. 0.1)
- p_g u brojniku predstavlja problem
 - Tamo gdje je p_{data} približno 0, a p_g velika, "pogrešno"
generirani uzorci se neće približavati p_{data}
- Stoga se β postavlja na 0 – stoga "jednostrano"

One-sided label smoothing

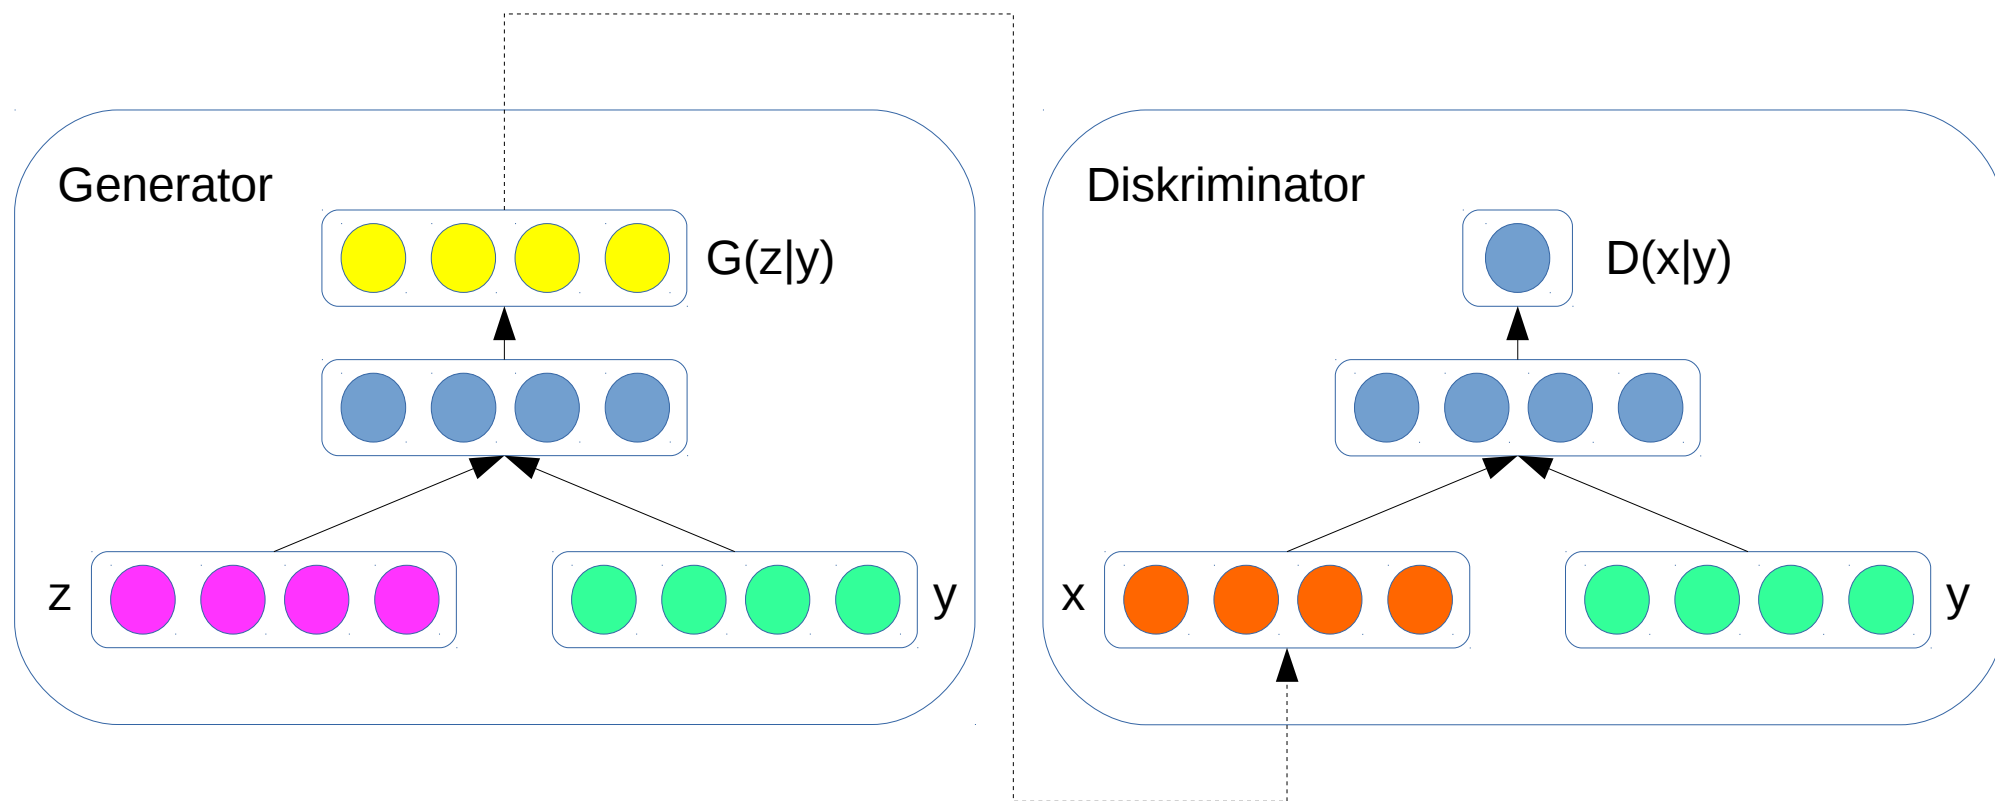
- α ne utječe na točnost nego samo na sigurnost u pozitivnu klasu
- Prednosti
 - Sprječava diskriminator da prosljeđuje veliki gradijent generatoru
 - Smanjuje se utjecaj vrlo uspješnih uzoraka

Balans G i D

- Želimo da diskriminator bude što bolji
 - D je obično veći i dublji
 - Možda je dobro osvježavati D češće nego G
- Za neke funkcije cijene može biti problem ako je D predobar, pogotovo u početku kada je G loš
 - Jedno rješenje je label smoothing

Korištenje označavanja

- Class conditional model
- Poboljšava subjektivnu kvalitetu slika




Zašto je GAN dobar

- Zašto ne generira mutne uzorke kao VAE
 - Ne zna se
 - Nije fokusiranje na drugačiju divergenciju
- Sličnost sa reinforced learning
 - Diskriminator daje ocjenu, ali se i on mijenja

DCGAN


- Deep Convolutional GAN
- Generiranje slika iz slučajnog vektora
- Sličnost sa CNN
- Stride veći od 1 (D) i manji od 1 (G)
 - Alternativa pooling slojevima
 - Veza nije predefiniрана nego se optimizira
- Batch normalization (G i D)
 - Svugdje osim u izlaznom sloju generatora i ulaznom sloju diskriminatora
- Leaky ReLU aktivacija osim u izlaznom sloju (G)
- Eliminacija FC slojeva (G i D)

DCGAN - generator




Kako koristiti GAN

- G za generiranje
- Ako se D trenira da odredi klasu uzorka (sve moguće klase plus fake klasa)
 - D se tada može koristiti za klasifikaciju



Što radi VAE

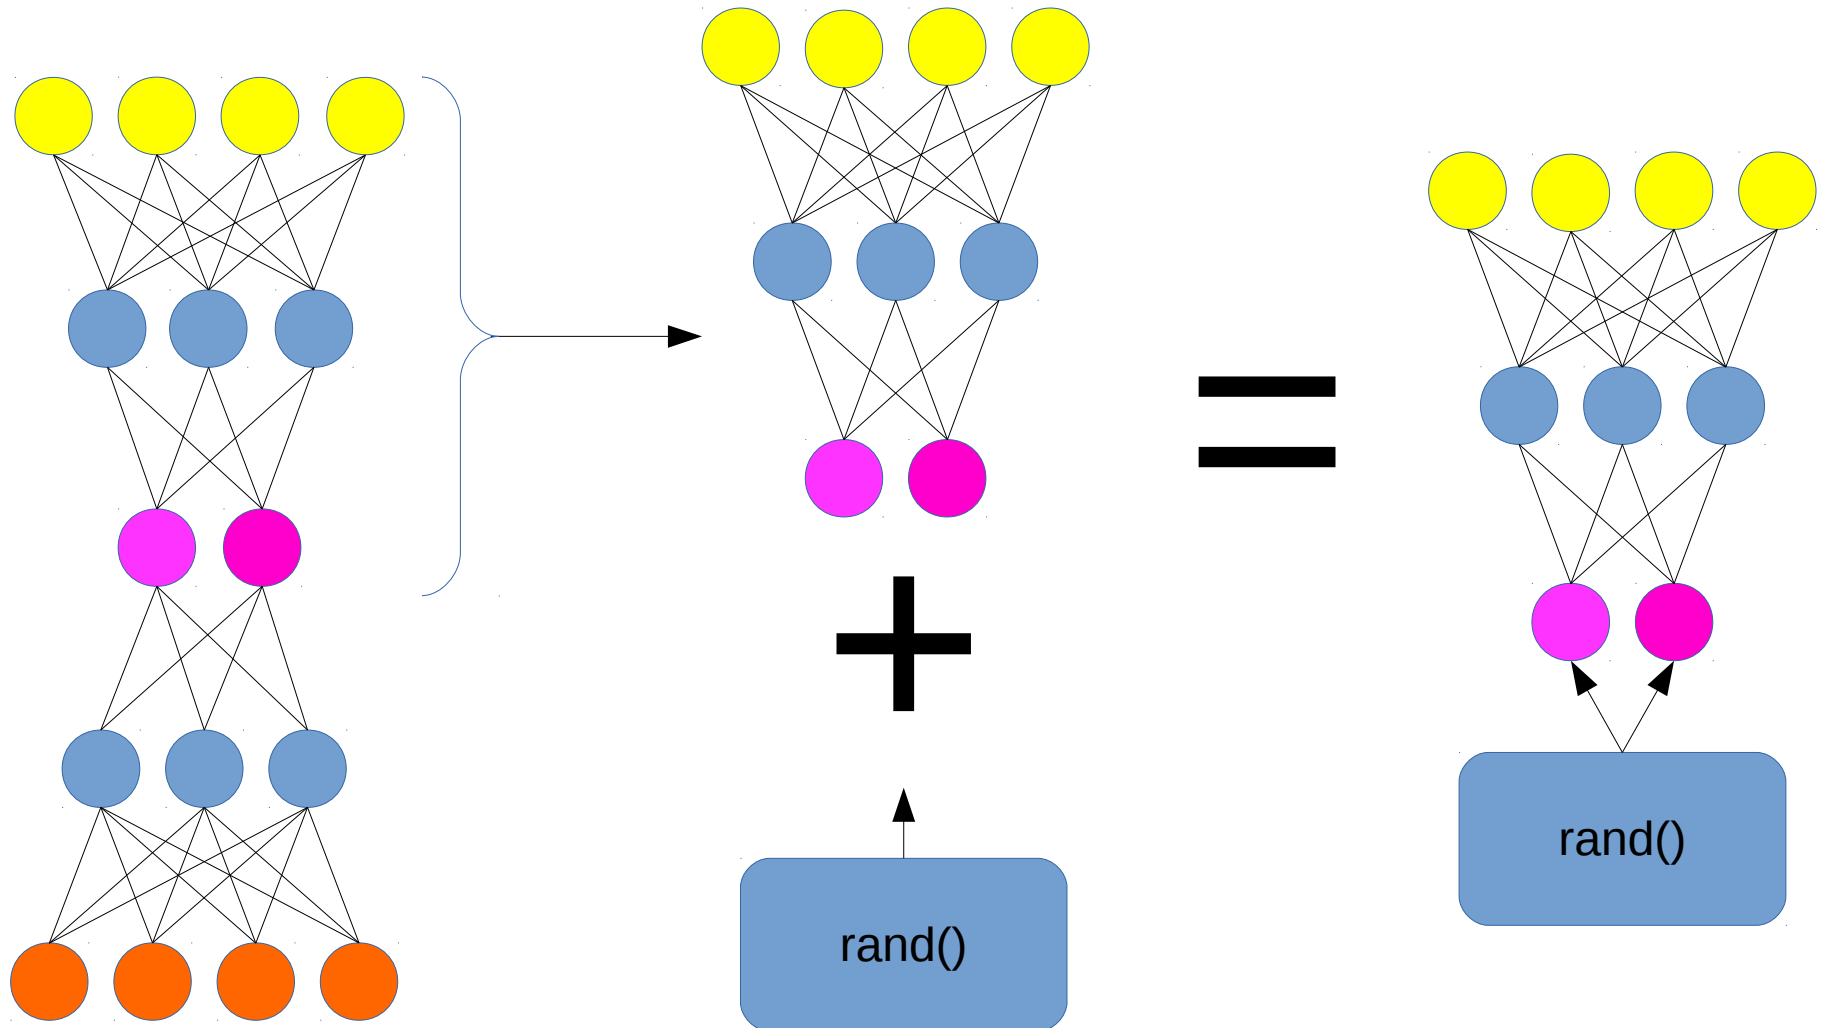
- Diskriminacija



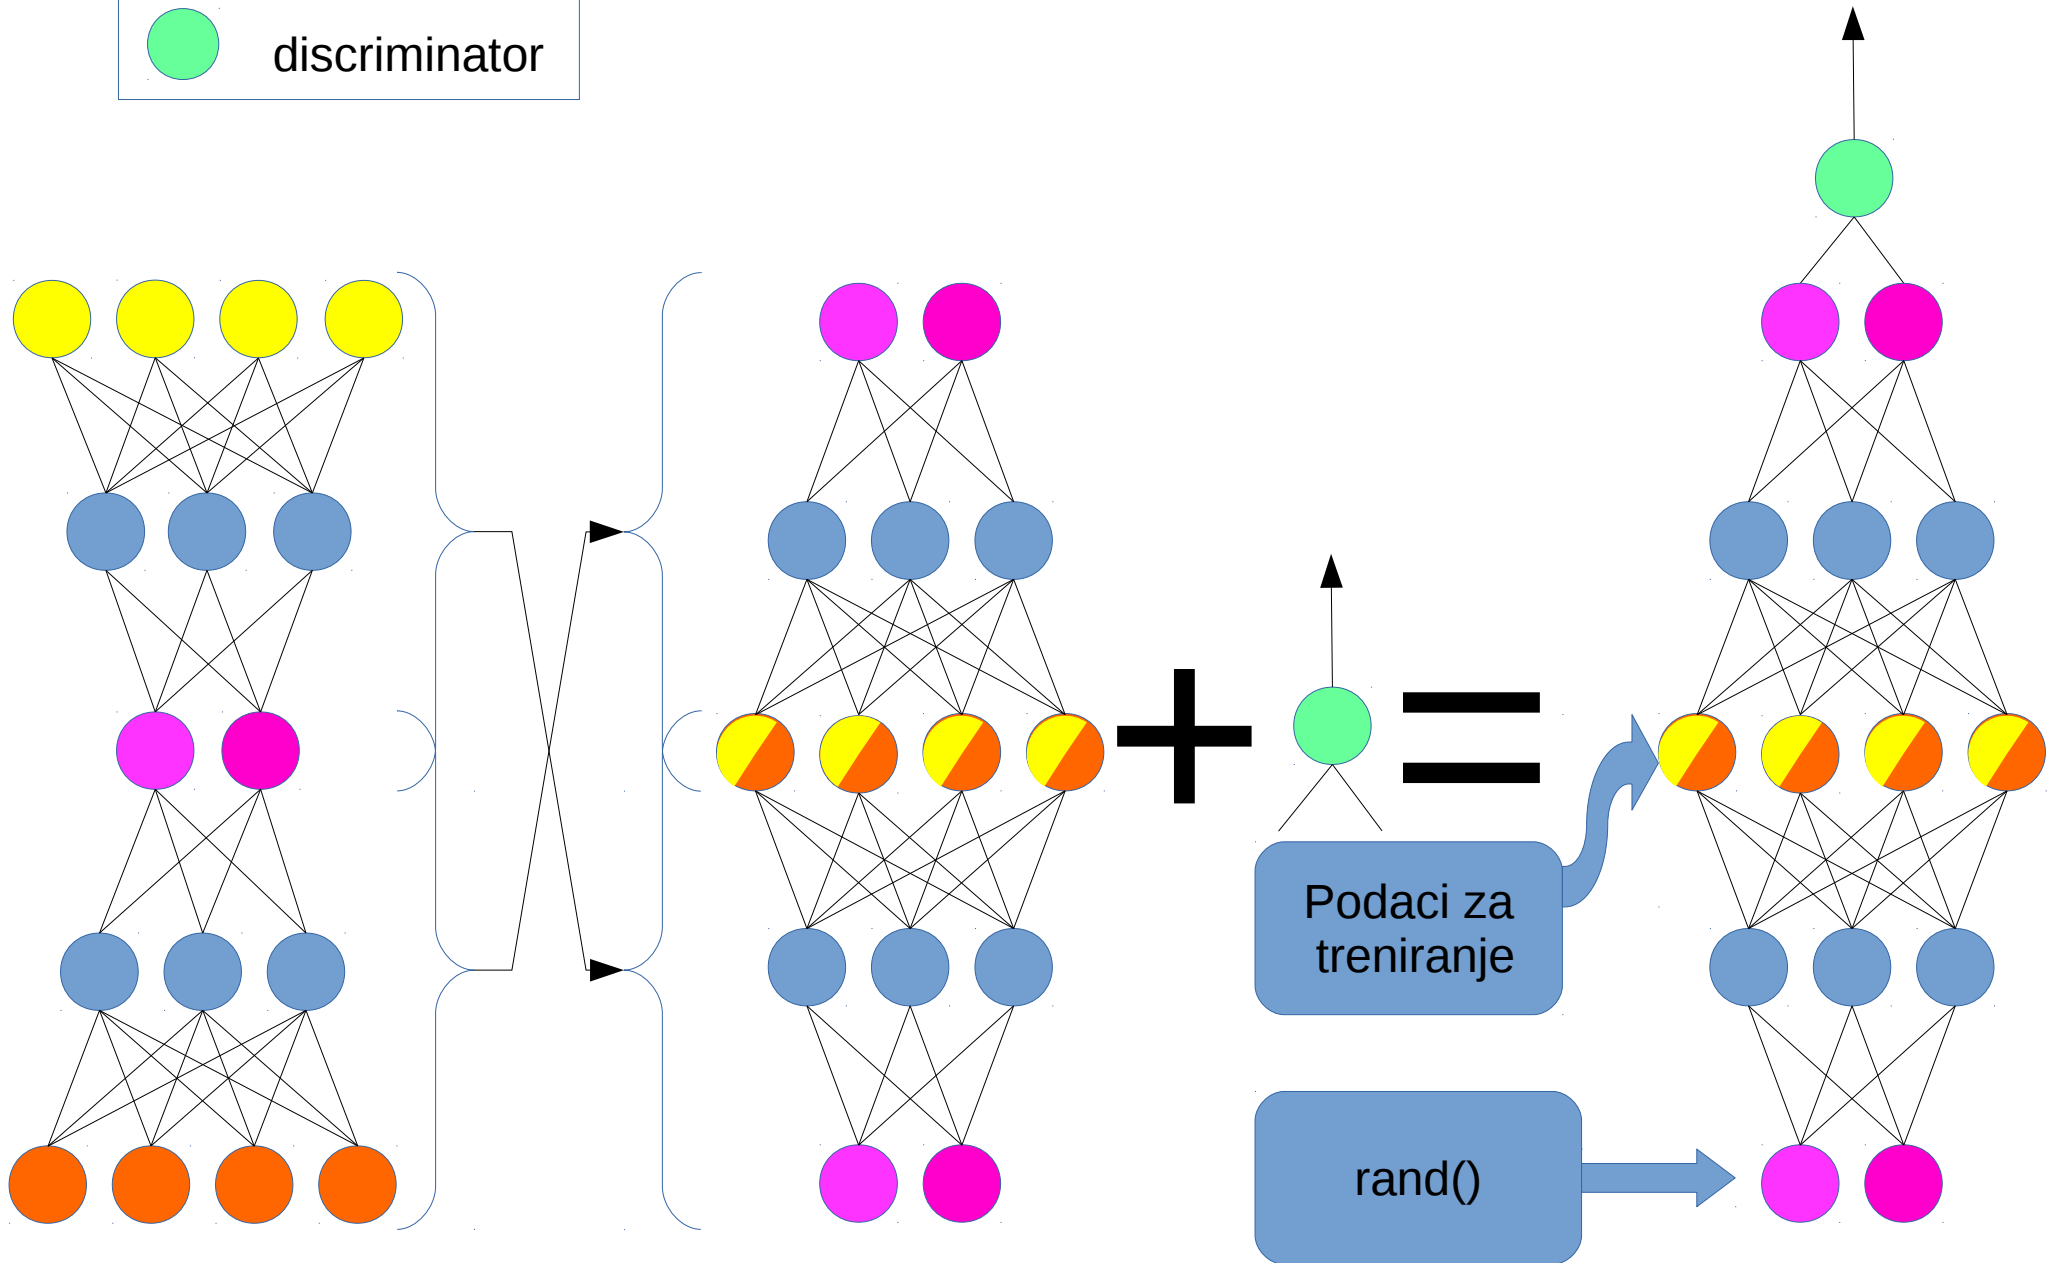


Što radi VAE

- **Generiranje uzoraka**






Što radi GAN





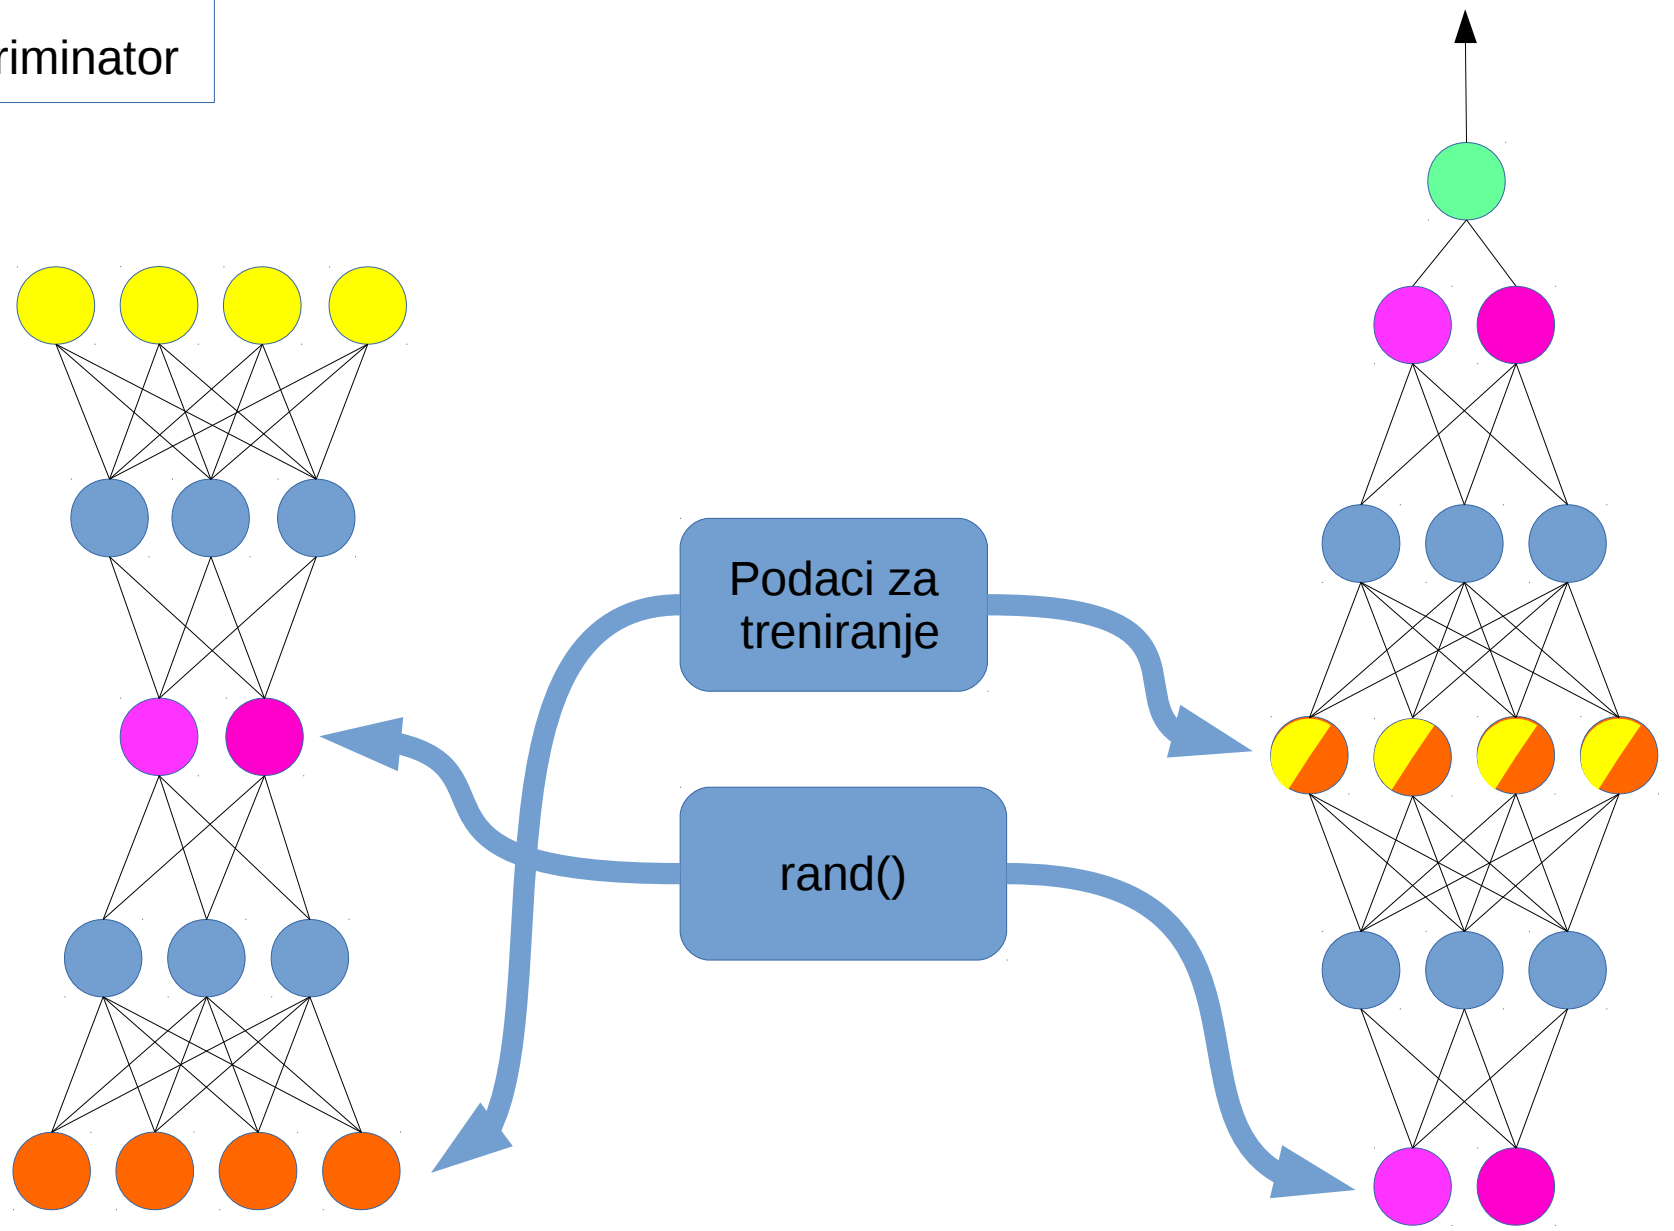
Što radi GAN

- Diskriminacija i generiranje



- real data
- gen. data
- features
- discriminator

VAE vs. GAN



Mogućnosti

