



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Óbudai Egyetem
Neumann János Informatikai Kar

Alkalmazott gépi tanulás (DNN) a kutatási-fejlesztési folyamatokban

Dr. Kertész Gábor

kertesz.gabor@nik.uni-obuda.hu

A Neumann János Informatikai Kar TDK tevékenységét és konferenciáit támogatja a Nemzeti Tehetség Program és a Miniszterelnökség, az Emberi Erőforrás Támogatáskezelő által kiírt "Hazai Tudományos Diákköri műhelyek és rendezvényeik támogatása" című pályázata (NTP-HHTDK-20).



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Tartalom

1. Mi az a gépi tanulás?
2. Neurális hálózatok, mély tanulás
3. Megerősítéses tanulás
4. Metric learning



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Mi az a gépi tanulás?

algorithm

when programmers
don't want to explain what they did

heuristic

when programmers
can't explain what they did


machine learning


when programmers
don't know what they did



Terminológia

- Artificial Intelligence
 - „A computer would deserve to be called intelligent if it could deceive a human into believing that it was human” – Alan Turing
- Machine Learning
 - Tanulásra képes rendszerek: teljesítmény javítása tapasztalatszerzés által
 - Pl: SVM, döntési fák, neurális hálózatok, genetikus algoritmusok, stb.
- Deep Learning
 - Mély neurális hálózatokon alapuló gépi tanulási algoritmusok





Students

ML Applications

Maths

ML Prof

Students



A mesterséges neuron

A mesterséges neuronok a biológiai neuron által ihletett egyszerű, bemenettel és kimenettel rendelkező feldolgozó egységek

A neuron az egyes bemenetekhez súlyértékeket tárol, amelyekből súlyozott összeget kalkulál:

$$y = \sum_{i=1}^N w_i x_i$$


Ahol y a kimenet, x_i az N darab bemeneti paraméter i -edik eleme, w_i pedig az ehhez tartozó súlyérték.



A mesterséges neuron

$$y = \sum_{i=1}^N w_i x_i$$

A neuron tanítása a w_i paraméterek olyasfajta módosítását jelenti, hogy a kimeneti y érték hibája minimális legyen.





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Egy gyors példa – az ingatlanos

- Egy ingatlanos egy lakás árát annak különböző paramétereire alapján képes megbecsülni, mint például:
 - Terület
 - Elhelyezkedés
 - Építés éve
 - Szobák száma
 - Kertkapcsolat
 - Légkondicionáló
 - Állapot
 - stb.





Egy gyors példa – az ingatlanos

- Az ingatlanos a fejében valójában egy modellt épít fel: a különböző paraméterek különböző súlyokkal vannak számításba véve, ezek szorzatösszege alapján kerül megbecslésre az ár

Hogyan tanulta meg ezt a kereskedő?

- Több példát látott, amelyeknél ismert a lakás ára is: ezeket címkézett tanítómintáknak nevezzük
- A tanítóminták alapján felmérte a különböző paraméterek fontosságát, és a **kapcsolódó súlyértékeket** ennek megfelelően **változtatta**



Egy gyors példa – az ingatlanos

- Hogyan lehet a súlyokat finomhangolni?
- A tanítóminták (összesen M darab) és az aktuális modell alapján kiszámolható a hiba:

$$\text{Hiba} = \sum_{j=1}^M |\text{Várt érték}_j - \text{Becsült érték}_j|$$

- Alkalmazható az itt látható abszolút hiba (MAE – mean average error) helyett a négyzetes hiba is (MSE – mean squared error)
- A cél ennek a **hibának a minimalizálása** a súlyértékek módosításán keresztül. Ez persze megoldható random korrekciókkal is, de léteznek ennél szofisztikáltabb optimalizációs eljárások is



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Egy gyors példa – az ingatlanos

Ebben az esetben egyetlen neuron segítségével működtethető a modell

Mi a gond ezzel a megközelítéssel?

- A modell bár egyszerű összefüggéseket felfedez (pl. a közelmúltban épített nagy alapterületű lakás ára magas), de a komplexebb kapcsolatok felfedezésére alkalmatlan
 - Példa: XOR kapcsolat a bemeneti paraméterek között



Jellemzően két nagy csoportra szokás bontani:

- Felügyelt tanulás
- Felügyelet nélküli tanulás

Felügyelt tanulás esetén rendelkezésre állnak olyan tanítóminták, ahol **ismert az elvárt kimenet** is, így tanításkor mérhető a pontosság.

Felügyelet nélküli tanítás esetén **címkézetlen adatok** közötti összefüggések felismerése a cél, amely jellemzően csoportosítást, klaszterezést jelent.



Felügyelt gépi tanulás

Felügyelt gépi tanulás esetén a megoldandó feladatok a kimeneti érték típusa szerint jellemzően kétfélék lehetnek:

- Regresszió

Ebben az esetben a **kimenet számszerű vagy folytonos**, mint az ingatlanos árbecslése esetén

- Klasszifikáció

Amennyiben a **kimenet kategorikus**, akkor annak megbecslésére van szükség hogy egy adott elem a paramétereit alapján mely osztályba sorolható.

Az osztályok számától függően megkülönböztethetünk bináris vagy többosztályú klasszifikációt.



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY


Felügyelet nélküli tanulás

- Nem állnak rendelkezésre címkék a mintákhoz
- Akkor mit tanul a rendszer?
 - Dimenziócsökkentés
 - Klaszterezés



Dimenziócsökkentés


- Főleg megjelenítéshez, kettő vagy három dimenzióban
- Főbb jellemzők megtartása mellett tömörítés





Klaszterezés

- Hasonlóan paraméterezett minták egy csoportba tartoznak, határozzuk meg ezeket a csoportokat





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Klaszterezés

- Ismert algoritmusok:
 - K-Means
 - DBSCAN
- Mindkettő elhangzik a *Haladó Algoritmusok* tárgy keretein belül:
 - <https://users.nik.uni-obuda.hu/halal/main.pdf>, 9. fejezet



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Neurális hálózatok, mély tanulás




ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

A neurális hálózatokról dióhéjban

Neurális hálózatoknál tradicionális felépítés a többrétegű előrecsatolt hálózat, ahol több neuron **rétegek**be rendezve kerül összekapcsolásra.

Ezen hálózatok esetén az egyes rétegek neuronjainak kimenetei a következő réteg minden bemenetére lesznek rákötve, kezdve a bemeneti paraméterek számával azonos méretű bemeneti réteggel.





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

A neurális hálózatokról dióhéjban

$$A_j = \varphi \left(\sum_{i=1}^N w_i x_i + b \right)$$

Ahol A_j jelöli a j . neuron aktivációját, φ az aktivációs függvényt, w_i, x_i az i . súly és bemenet értékeket, b pedig az eltolást.




A neurális hálózatokról dióhéjban

$$A_j = \varphi \left(\sum_{i=1}^N w_i x_i + b \right)$$


Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$




tanh

$$\tanh(x)$$



ReLU

$$\max(0, x)$$





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY


A neurális hálózatokról dióhéjban

- Bár a paraméterszám növekszik, és a tanítás folyamata lassul, de a több rétegű hálózatok egyértelműen jobban teljesítenek a komplexebb jellemzők kinyerésében
- A mélyebb rétegek összetettebb jellemzőket képesek felismerni
- Ha megnöveljük a rétegszámot, akkor elkezdhetünk mély neurális hálózatokról beszélni



Mély Neurális Hálózatok

Simple Neural Network




● Input Layer

● Hidden Layer

● Output Layer

Deep Learning Neural Network





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Alkalmazások



Source Sequence



Our Reenactment
(Full Head)



Averbuch-Elor et al. 2017





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY


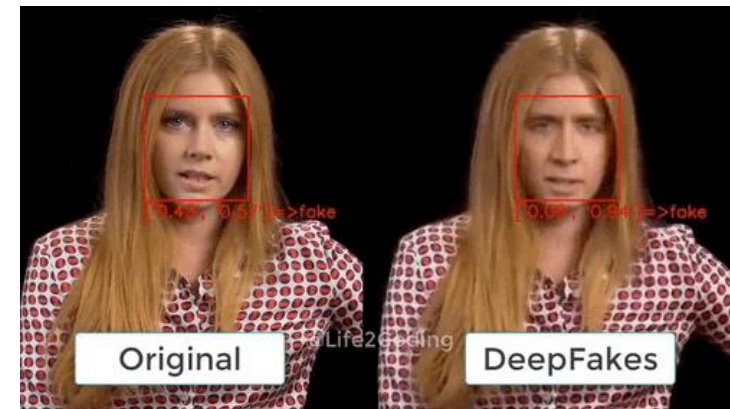

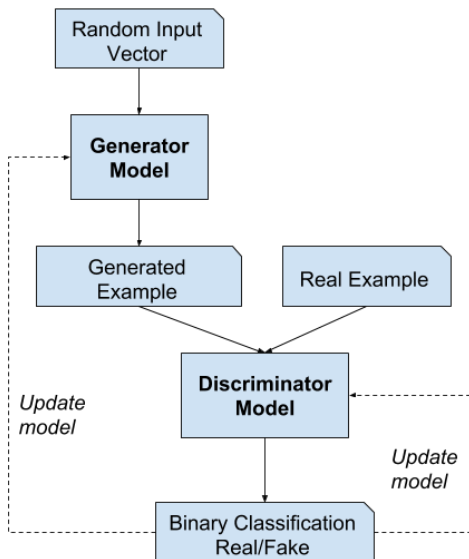
Alkalmazások





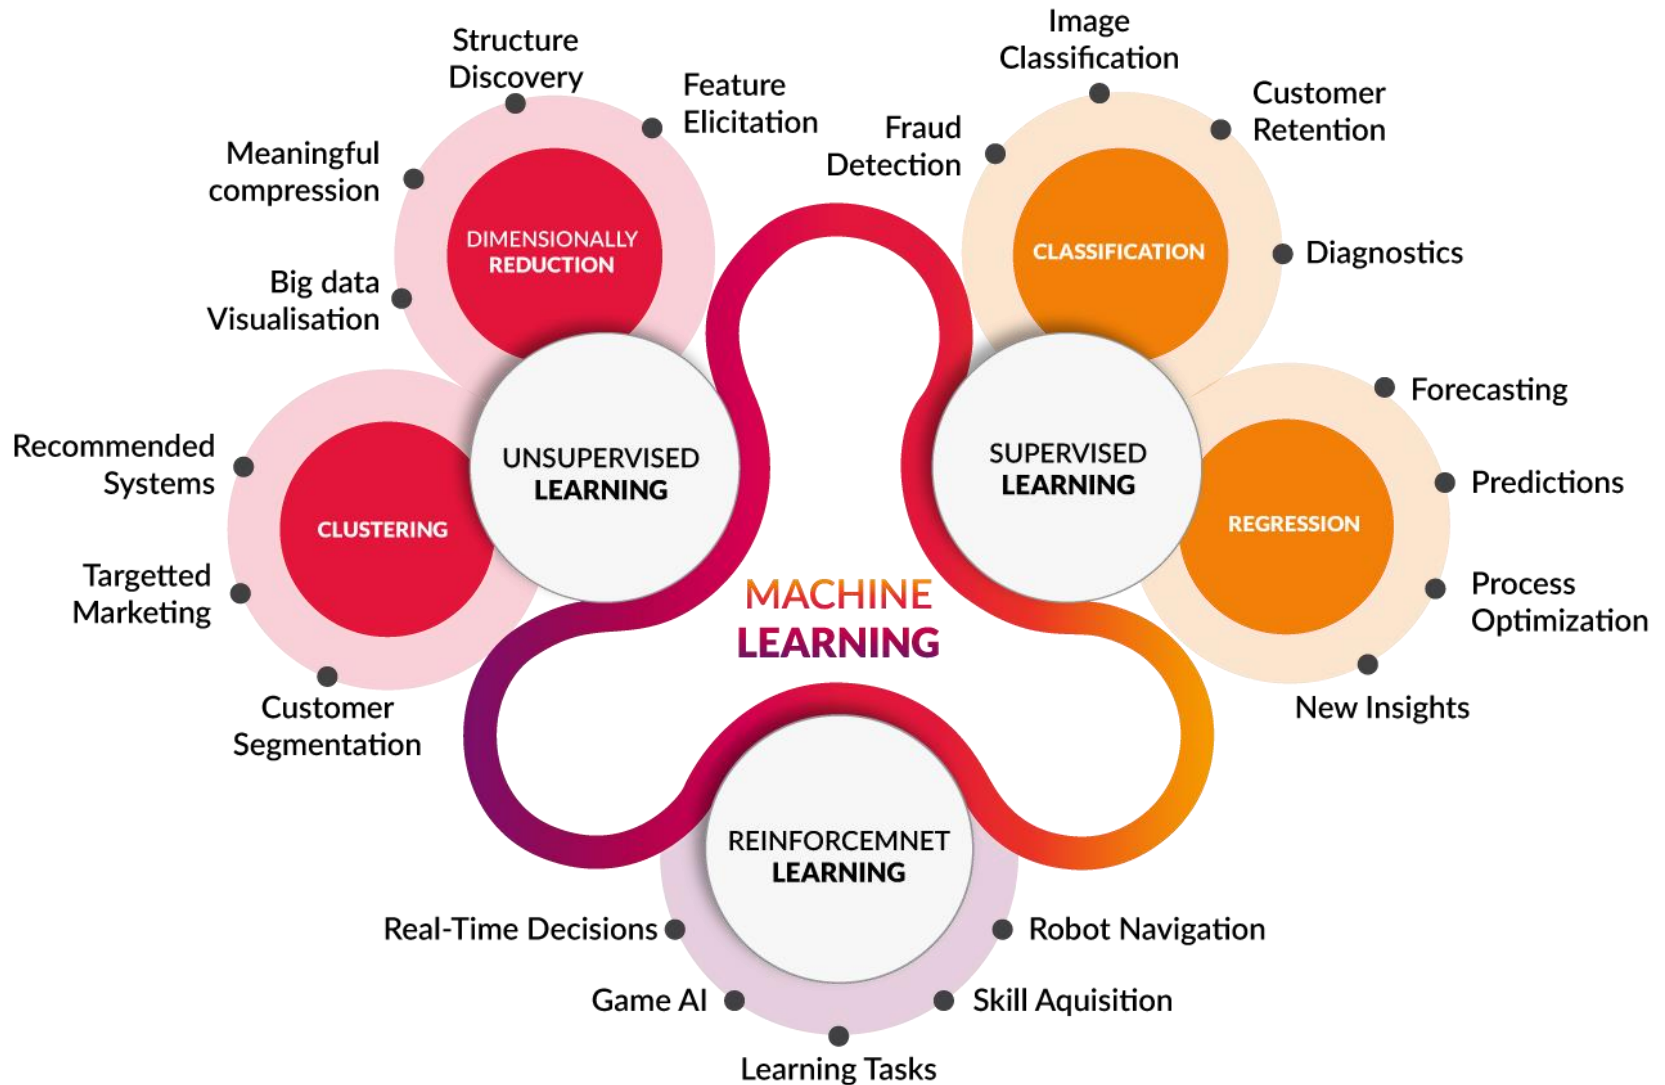
Generative Adversarial Networks

- Ian Goodfellow, Yoshua Bengio et al
- Generator vs Discriminator





Gépi tanulás





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY


Megerősítőes tanulás



Megerősítéses tanulás

A gépi tanulás egy különleges kategóriája a megerősítéses tanulás: ebben az esetben a feladat egy ügynök **dinamikus környezetben** való döntéshozatalának optimalizálása a környezettől kapott jutalmak maximalizálására.

Tipikus példák ilyen esetekre a különböző játékokat automatikusan játszó mesterséges ügynökök, vagy épp a Go-világbajnokot legyőző számítógépes program.





Megerősítőes tanulás

- Hogy illik az eddigiekhez?
- A felügyelt tanulás statikus a címkék a mintákhoz vannak rendelve, míg itt a döntés a környezet állapotától függ
- Nincs explicit jó döntés: a felügyelt tanulás esetén adott hogy mit várunk, az ágens döntésekor nem egyértelmű a választás értékelése
- Az ügynök tanulása egyrészt felfedezés – másrészt a tanultak alkalmazása



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Modern eredmények

- Playing Atari with Deep Reinforcement Learning
 - <https://arxiv.org/pdf/1312.5602v1.pdf>
 - <https://www.youtube.com/watch?v=V1eYniJ0Rnk>






ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Modern eredmények

- AlphaGo
 - <https://www.youtube.com/watch?v=WXuK6gekU1Y>





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Modern eredmények


- Autonóm járművek





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Modern eredmények





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Modern eredmények

- <https://cdn.openai.com/dota-2.pdf>
- <https://deepmind.com/blog/article/capture-the-flag-science>





ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Ajánlott Irodalom

- <http://incompleteideas.net/book/RLbook2020.pdf>



Reinforcement Learning

An Introduction
second edition

Richard S. Sutton and Andrew G. Barto



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

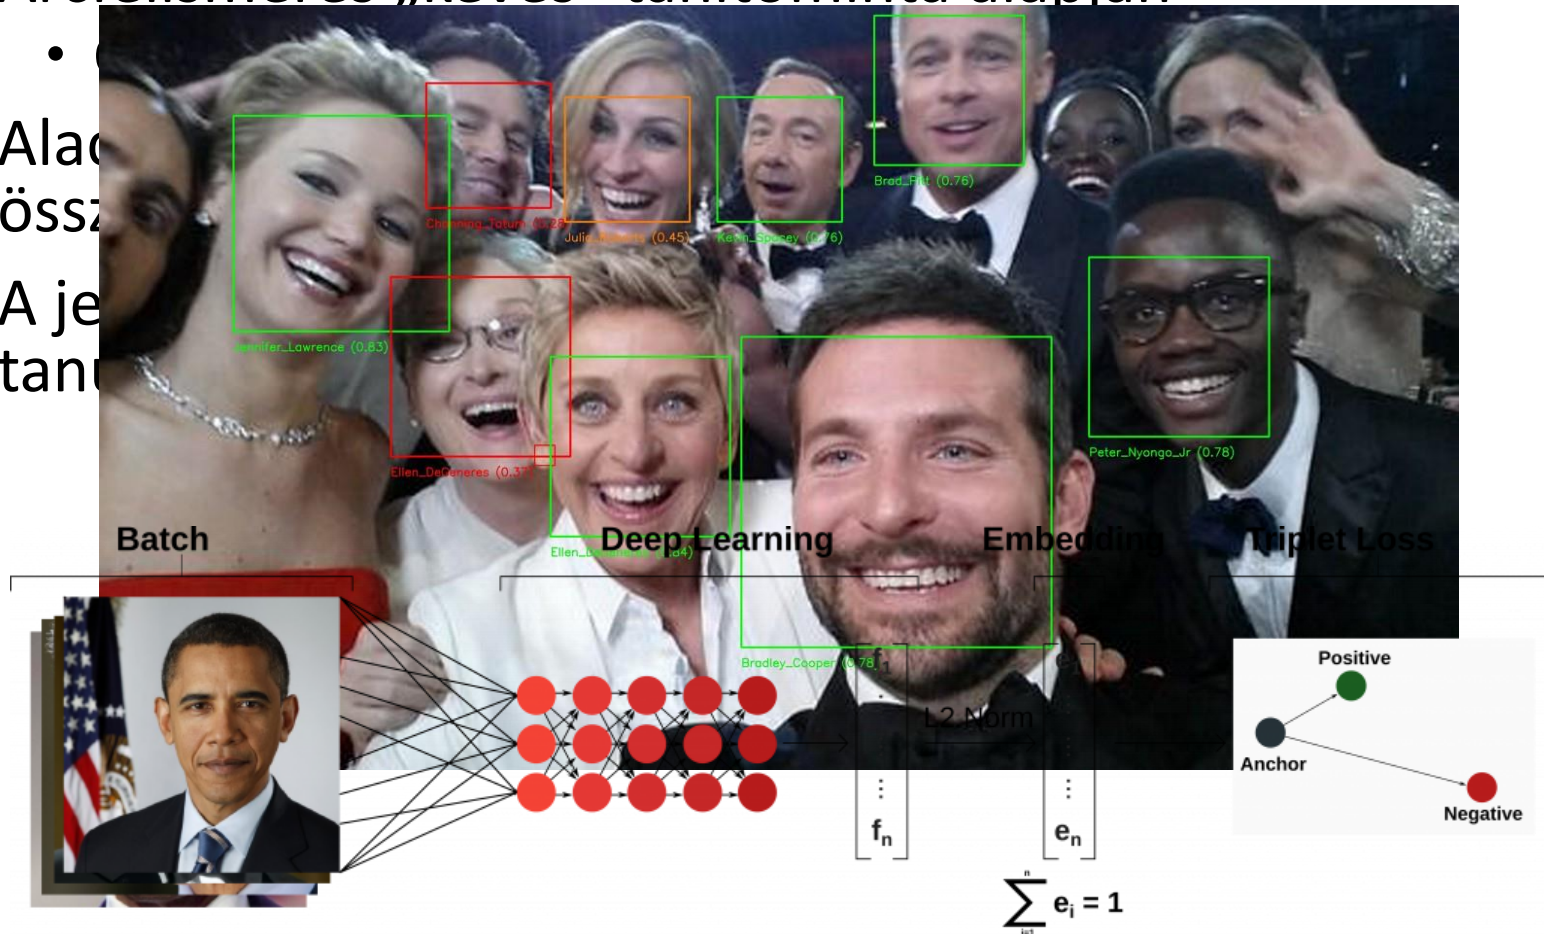
Metric learning



Arc alapú azonosítás



- Arcfelismerés „kevés” tanítóminta alapján

- Alap
- Össz
- A je
- tan



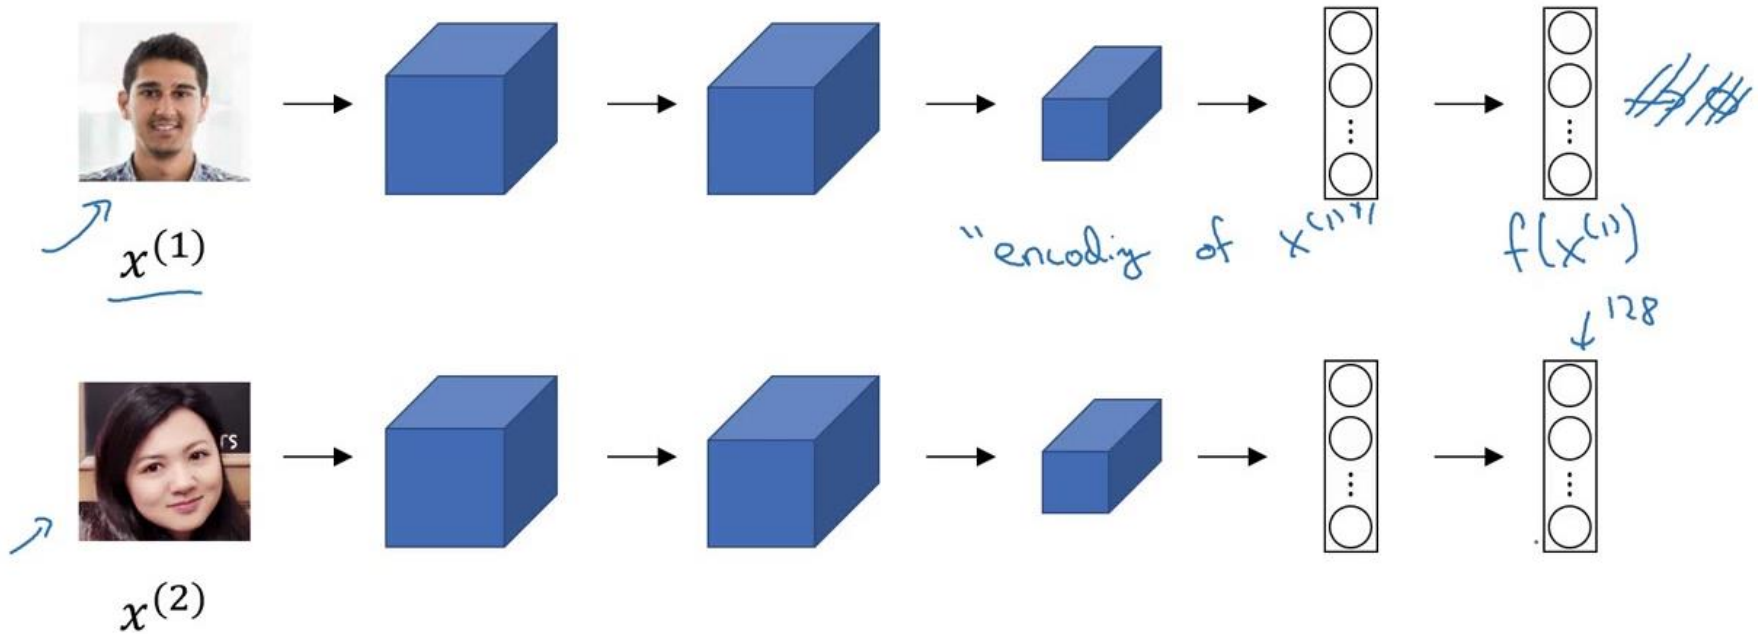


Autoencoder



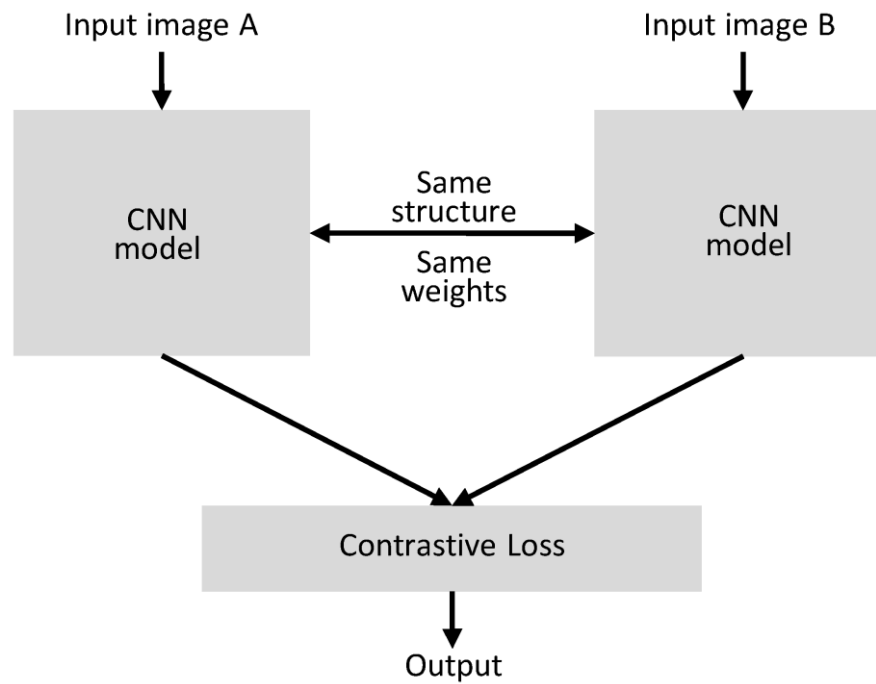


Dimenziócsökkentés





Siamese Networks

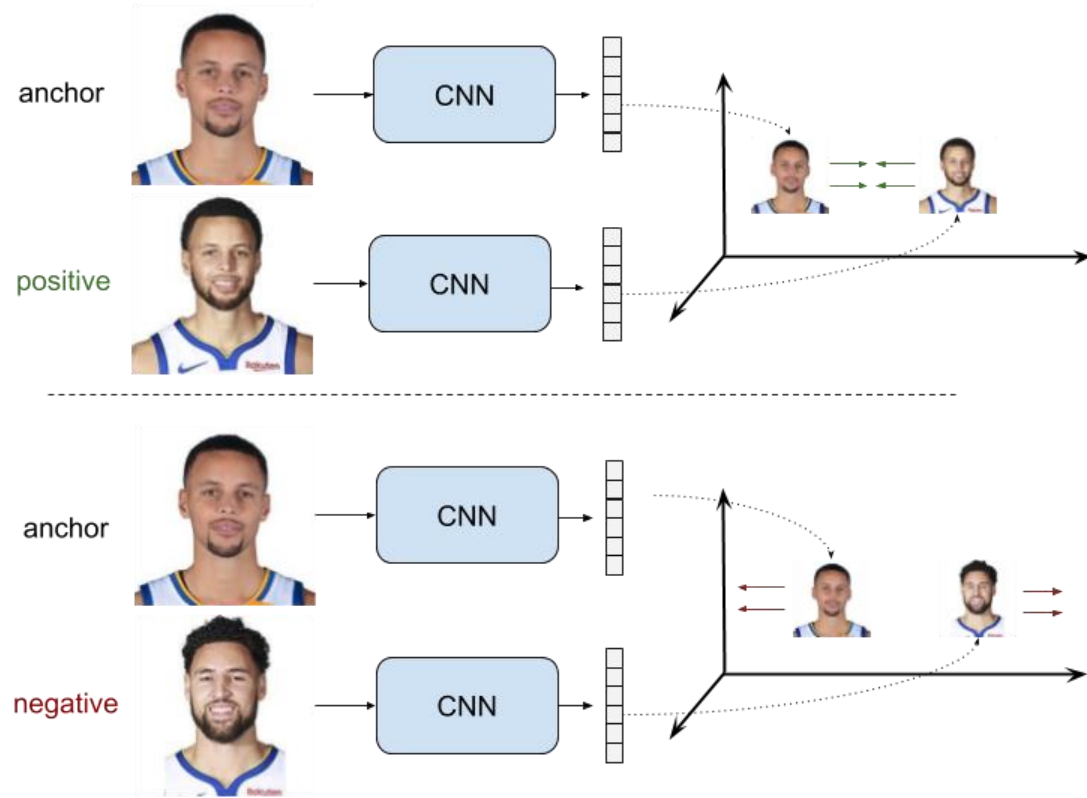




Siamese Networks

- Contrastive loss


$$\mathcal{L}_{\text{contrastive}} = (1 - Y) \frac{1}{2} \max(0, (m - d(x_1, x_2)))^2 + Y \frac{1}{2} d(x_1, x_2)^2$$





Siamese Networks

$$\mathcal{L}_{\text{contrastive}} = (1 - Y) \frac{1}{2} \max(0, (m - d(x_1, x_2))^2) + Y \frac{1}{2} d(x_1, x_2)^2$$





新建票务

Baidu 百度



请将脸移入框内

拍摄

姓名:

证件号码:

证件类型:

身份证

护照

军官证

票务种类

西梯门禁

电梯门禁

门禁截止日期:

11月	11月	11月	11月	11月	11月	11月
11	11	13	14	15	16	17

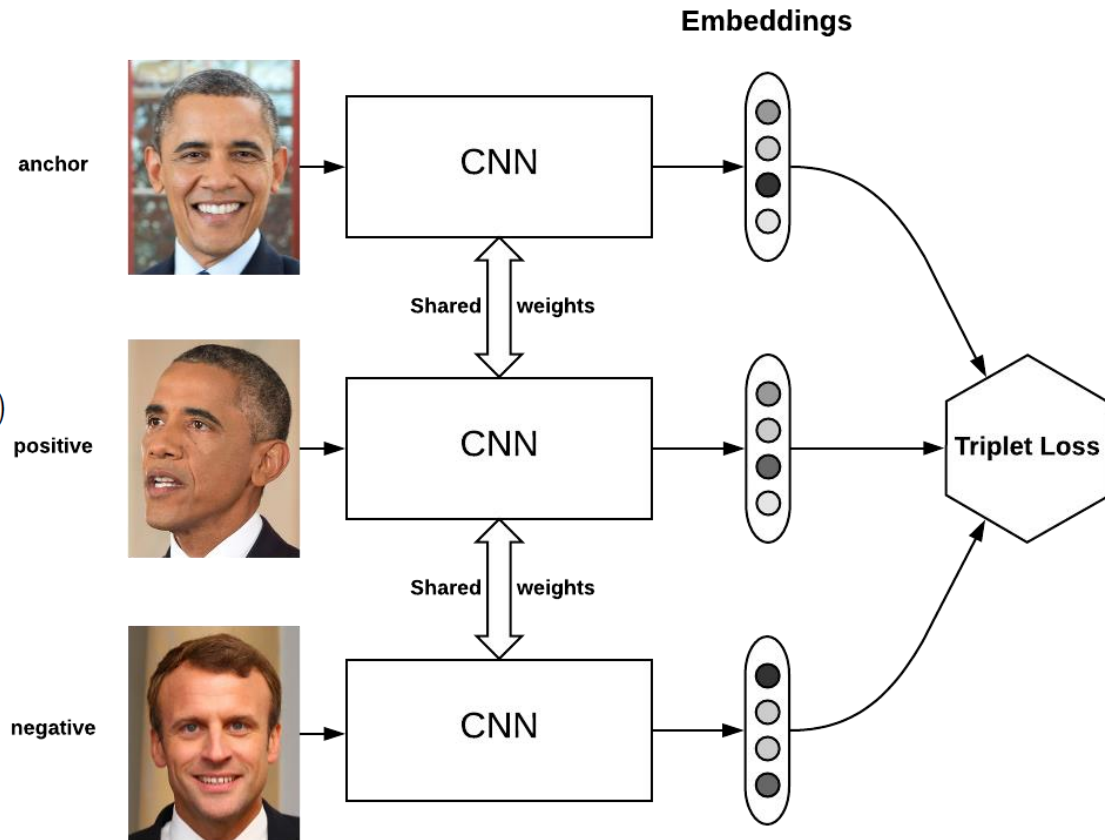
更多日期>>

创建



Triplet loss, Triplet networks

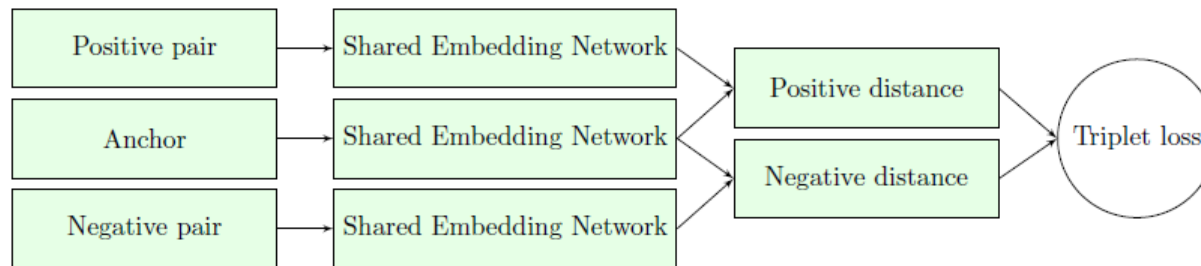
$$\mathcal{L}_{\text{triplet}} = \max(0, m + d(x_a, x_p) - d(x_a, x_n))$$





Triplet loss

$$\mathcal{L}_{\text{triplet}} = \max(0, m + d(x_a, x_p) - d(x_a, x_n))$$



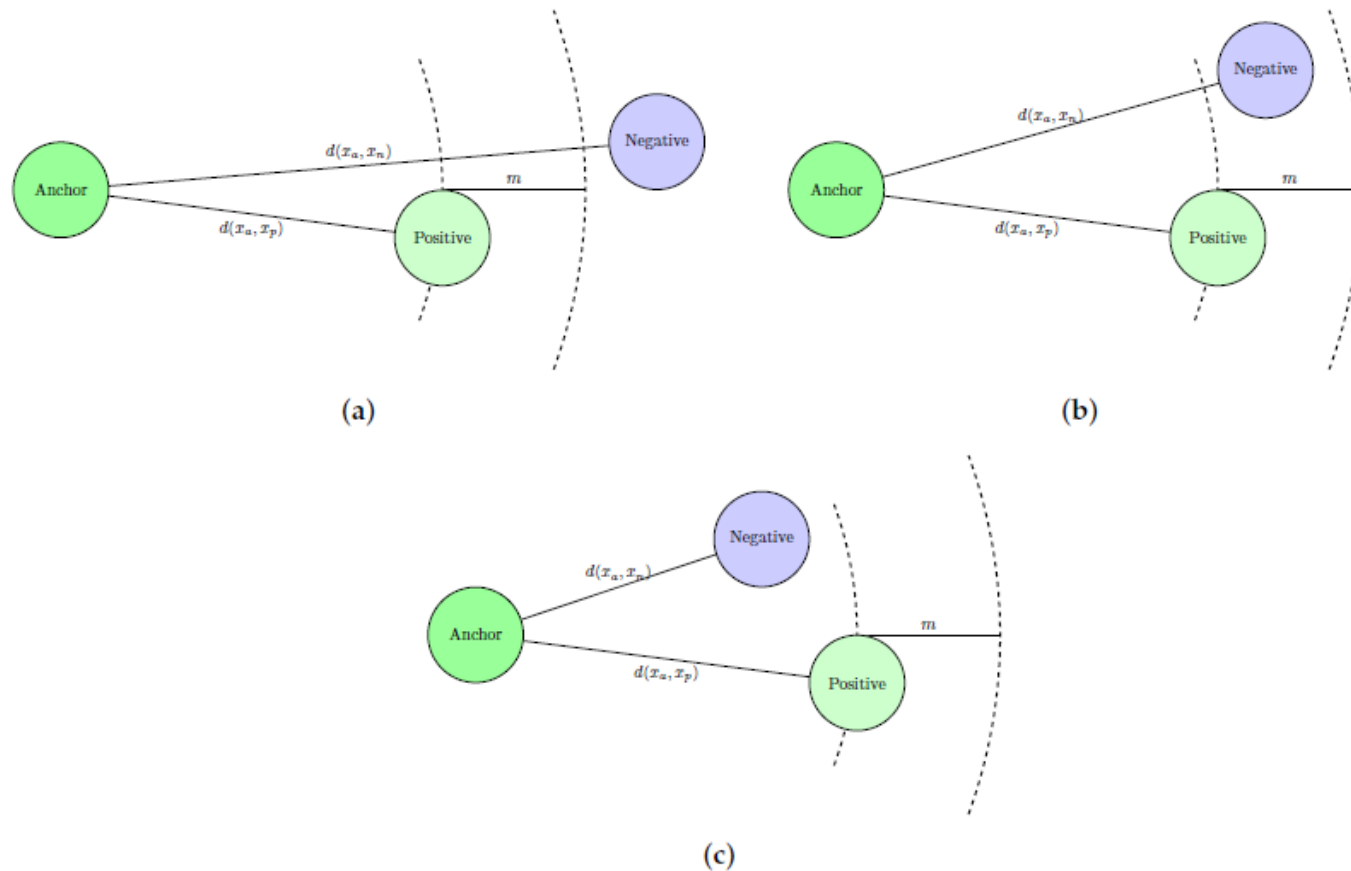


Figure 5. Illustration of different types of triplets. Subfigure (a) shows an easy negative, where $d(x_a, x_n) > d(x_a, x_p) + m$, resulting in zero loss. Subfigure (b) illustrates a semi-hard negative, as $d(x_a, x_p) < d(x_a, x_n) < d(x_a, x_p) + m$, resulting in a positive loss. On subfigure (c), the so-called hard negative is visualized, where $d(x_a, x_n) < d(x_a, x_p)$.



Metric learning

- Sziámi vagy triplet architektúrák
- Reprezentáció alacsonyabb dimenzionalitásban
- Távolság alapú szimilaritás-mérés
- Széleskörű alkalmazási lehetőségek
 - Arc-alapú azonosítás
 - Aláírás verifikáció
 - stb.
- Érdekesség, hogy ezek a modellek olyan megoldásokban is alkalmazhatóak, ahol az objektumokat tanítás során nem látta a modell
 - One-shot learning
 - Few-shot learning



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Köszönöm a figyelmet!

Dr. Kertész Gábor

kertesz.gabor@nik.uni-obuda.hu

A Neumann János Informatikai Kar TDK tevékenységét és konferenciáit támogatja a Nemzeti Tehetség Program és a Miniszterelnökség, az Emberi Erőforrás Támogatáskezelő által kiírt “Hazai Tudományos Diákköri műhelyek és rendezvényeik támogatása” című pályázata (NTP-HHTDK-20).



EMBERI ERŐFORRÁS
TÁMOGATÁSKEZELŐ



MINISZTERELNÖKSÉG
CSALÁDOKÉRT FELELŐS TÁRCA NÉLKÜLI MINISZTER



Nemzeti
Tehetség Program