

Masarykova univerzita

Fakulta informatiky



Deep Learning

PB016 Umělá inteligence I

Tereza Katreniaková

UČO: 445298

# Obsah

Úvod.....	3
Začiatky Deep Learningu.....	4
Súčasnosť.....	4
Využitie.....	5
Deep Dream .....	5
Neural Talk.....	7
Google Translate .....	7
Záver .....	8
Zdroje.....	9

# Úvod

Deep Learning je metóda strojového učenia, čiže metóda, ktorá umožňuje počítaču “myslieť”, učiť sa, a na základe poznatkov sa rozhodovať bez toho, aby bola na tieto úlohy priamo naprogramovaná. Snaží sa o napodobenie fungovania ľudského mozgu, čo ale nie je možné jednoznačne zalgorithmizovať, keďže ľudský mozog funguje okrem mechanických princípov aj na základe pocitov, či intuície. Učenie v mozgu majú na starosti neuróny komunikujúce medzi sebou prostredníctvom synaptických spojení, ktoré vznikajú na základe skúsenosti a cvičenia.

Tento princíp sa snažia napodobiť umelé neurónové siete, ktoré majú za úlohu naučiť sa rozpoznávať reč, obraz, triediť predmety, hrať hry, či navigovať v neznámom priestore.

Možnosti neurónových sietí boli v minulosti veľmi obmedzené, takže sa zdalo že na nich postavená umelá inteligencia nebude v praxi využiteľná. Hlavným problémom bola nedostatočne vyvinutá výpočtová technika, čo sa však v súčasnosti zmenilo a záujem o neurónové siete znovu narastá.

Myšlienka deep learningu a jej vývoj je dnes témou, ktorou sa zaoberajú všetky veľké technologické korporácie (Google, Facebook, Microsoft, IBM,...) a vznikajú aj nové firmy založené na tejto myšlienke. Napríklad firma face.com vyvinula spôsob ako identifikovať ľudí podľa tváre a dnes je už súčasťou Facebooku a rozpoznáva ľudí s presnosťou 97%.

## Začiatky Deep Learningu

Za začiatky Deep Learningu môžeme považovať 50. roky 20. storočia, kedy vznikla prvá umelá neurónová sieť spolu s tréningovými metódami - perceptron. Je to jednoduchá jednovrstvová neurónová sieť pozostávajúca iba z jedného neurónu.

Tento neurón môže mať viacero vstupov, ale len jeden výstup. Vstupné údaje sú sčítané so synaptickými váhami, ktoré určujú ich dôležitosť a konštantou bias (prah).

Následne sú transformované prenosovou funkciou a poslané na výstup. Perceptron však nebol schopný naučiť sa ani funkciu XOR.

Riešenie tohto problému prišlo až o 20 rokov neskôr, kedy bol objavený algoritmus spätnej propagácie chyby pre viacvrstvové neurónové siete, ktoré sú schopné zachytiť aj veľmi zložité závislosti. Prvá vrstva je vstupná, posledná vrstva je výstupná, ostatné sa nazývajú skryté. Každý neurón má na vstupe výstup z predchádzajúcej vrstvy, a svoj výstup posúva ďalej vrstve.

V algoritme spätnej propagácie chyby sa najskôr všetky váhy siete nastavujú náhodne, pre tréningové dáta sa vypočítajú výstupné hodnoty siete, porovnajú s očakávaným výsledkom a rozdiel sa vráti do vstupnej vrstvy, pri čom sa upravujú váhy aby sa zmenšila chyba. Tento postup sa opakuje kým sa nenájde minimálna chyba. Problémom je, že existuje veľké množstvo rôznych nastavení váh vstupných vrstiev, a algoritmus často skončí iba v lokálnom minime chyby.

V 90. rokoch objavili vedci Support Vector Machines, ktoré boli rýchlejšie a mali lepšie výsledky, a tak záujem o neurónové siete upadol.

## Súčasnosť

Výskumné tímy zaoberajúce sa neurónovými sieťami sa našťastie neúspechom nenechali odradiť a zamerali sa na hľadanie príčin problémov vo viacvrstvových neurónových sieťach. Zistili, že hlavnými problémami boli nedostatočné technické parametre počítačov, malé množstvo tréningových dát a nevhodné inicializovanie počiatkových váh. V dnešnej dobe máme už dostatočnú výpočetnú silu a takisto disponujeme veľkým množstvom dát, čo má zásadný význam.

Náhodná inicializácia váh sa dá nahradiť predtrénovaním siete - natrénovaním parametrov všetkých vrstiev neurónovej siete iba na základe jej vstupov. Ide o metódu strojového učenia bez učiteľa, ktorá sa snaží reprezentovať svoje vstupy iným spôsobom, a nie optimalizovať ju na základe požadovaných výstupov.

V súčasnosti existuje veľa techník slúžiacich na predtrénovanie neurónových sietí, napríklad Restricted Boltzmann Machines, Deep Kernel Machines, Deep Belief Networks, Deep Convolutional Networks, atď.

## Využitie

Zjednodušene povedané, aplikácie Deep Learningu nie sú naprogramované ako sa v rôznych situáciách správať, ale sú natrénované na veľkých dátach. Využívajú sa hlavne v analýze textových informácií, analýze hovoreného slova, rozpoznávanie obrazu či v simuláciách inteligentého správania sa.

Na príklade identifikácie tváre na obrázku vysvetlím princíp Deep Learningu. Analyzovať celú fotku do detailov nie sú schopné ani súčasné technológie, a preto to prebieha v niekoľkých úrovniach. Prvá vrstva by mohla identifikovať hrany v obrázku, ďalšia by mohla identifikovať objekty pozostavené z hrán (tvár, oči, uši, ...), ďalšia by zachytila ich všeobecné vlastnosti, až najvyššia by bola schopná identifikovať konkrétnu osobu.

## Deep Dream


Deep Dream Generator je program vytvorený spoločnosťou Google, ktorý využíva konvolučné neurónové siete na transformáciu obrázkov.

Algoritmus Deep Dream pôvodne slúžil na vizualizáciu toho, čo sa vlastne v hlbokých neurónových sieťach deje, čo “vidia” keď dostanú nejaký obrázok. Hlboké neurónové siete vyhľadávajú v obrázkoch rôzne vzory, a následne podľa vzorov obrázkov identifikujú. Akonáhle už mám sieť vytrénovanú je možné toto použiť spätne, a vzory začať generovať tak, že sieť požiadam aby iba ľahko upravila pôvodný obrázok. Po niekoľkých iteráciách vznikajú rôzne zaujímavé abstraktné diela.

Čiže keď dáme Deep Dreamu obrázok na ktorom mu niečo trochu pripomína psa, sieť tento efekt zosilní a objekt bude pripomínať psa ešte viac. V nasledujúcej iterácii sieť psa rozpozná silnejšie, a znovu tento efekt zosilní, a tak to pokračuje až kým sa na obrázku neobjaví detailne vykreslený pes.



Obr.1.



Obr.2.

Algoritmus Deep Style slúži na transformáciu obrázku pomocou štýlu iného obrázku. Je teda schopný pomocou vlastných vedomostí identifikovať štýl, a aplikovať ho na obrázok.

Na demonštráciu tohto algoritmu som použila fotografiu Fakulty informatiky MU (Obr.1), náhodný obrázok z internetu ako štýl (Obr.3). Vo výslednom obrázku (Obr.4) sú zachované hlavné črty budovy bez vážneho porušenia.



Obr.3.



Obr.4.

## Neural Talk


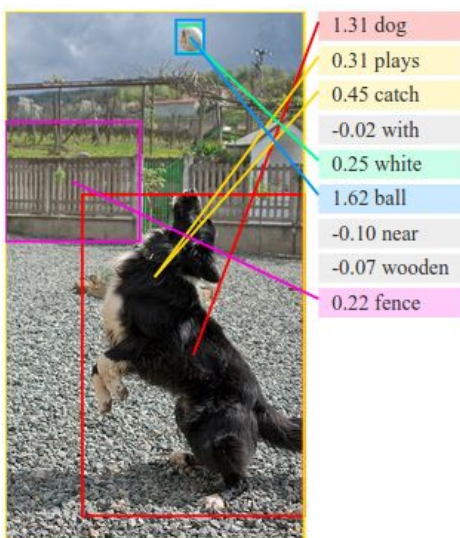
Neural Talk je projekt, ktorý generuje popisky obrázkov, kombináciou konvolučných a rekurentných neurónových sietí. Tento prístup využíva datasety obrázkov a ich slovných popisov aby sa naučil chápať vzťahy medzi jazykom a vizuálnymi dátami.

Dokáže nielen rozpoznať, čo sa na obrázku nachádza, ale sám sa učí identifikovať celé scény (skupinka ľudí hrá frisbee) a potom k nim napíše anglický popis, ktorý je v porovnaní s ľudským pozorovaním prekvapivo presný.

Dnes sa pri vyhľadávaní obrázkov spoliehame na ľuďmi ručne napísané popisky, ktoré nie vždy zahŕňajú všetko, čo sa na obrázku nachádza a tento software by mohol toto vyhľadávanie veľmi zefektívniť a zrýchliť. V budúcnosti by takáto technológia mohla pomáhať slepým ľuďom orientovať sa v priestore a rozoznávať čo je okolo nich.



a man and a woman riding  
on the back of an elephant



a woman is standing in  
front of a mirror

## Google Translate

V novembri 2016 spoločnosť Google oznámila, že pôvodný algoritmus pre službu Google Translate bude nahradený novou technikou založenou čisto na Deep Learningu.

Pôvodný algoritmus prekladal vety tak, že ich rozobral na slová a frázy a preložil nezávisle slovo po slove. Nový algoritmus pomocou rekurentnej neurónovej siete dokáže preložiť slová na základe kontextu celej vety a tiež sa dokáže učiť z už existujúcich prekladov.

Princíp je podobný ako pri rozpoznávaní obrazu, kde sa začína od najjednoduchších častí (pixely, neskôr hrany, rôzne vzory). Tu si rozložíme slovo na segmenty, ktoré vie sieť vo vnútri skombinovať tak, aby si odvodila ich význam. Po analýze textu, tá istá sieť celý text preloží. Chybovosť prekladu sa vďaka tomu znížila o 60%.

## Záver

Síce v dnešnej dobe pozorujeme pokrok umelej inteligencie, stále sa nevyrovná ľudskej. Pomocou Deep Learningu dokáže riešiť komplexné situácie, ktoré sa v minulosti zdali nemožné, no ani zďaleka nevieme vytvoriť celistvú umelú inteligenciu, ktorá by na svet dokázala reagovať podobne ako človek.



## Zdroje

<http://machinelearningmastery.com/what-is-deep-learning/>

<http://clanky.rvp.cz/clanek/c/Z/20855/co-dokazi-stroje-schopne-hlubokeho-uceni.html/>

<https://vyhledavani.sblog.cz/2013/01/09/deep-learning-budoucnost-strojoveho-uceni/>

<http://www.nytimes.com/2012/11/24/science/scientists-see-advances-in-deep-learning-a-part-of-artificial-intelligence.html>

<http://machinelearningmastery.com/inspirational-applications-deep-learning/>

[https://cs.wikipedia.org/wiki/Strojov%C3%A9\\_uk%C4%8Den%C3%AD](https://cs.wikipedia.org/wiki/Strojov%C3%A9_uk%C4%8Den%C3%AD)

[https://en.wikipedia.org/wiki/Artificial\\_neural\\_network](https://en.wikipedia.org/wiki/Artificial_neural_network)

<https://cs.wikipedia.org/wiki/Perceptron>

<http://www.etrend.sk/trend-archiv/rok-2015/cislo-50/umela-inteligencia-uz-klope-na-dvere.html>

<https://medium.com/@quantopy/machine-learning-nie-je-ani-m%C3%A1gia-ani-diabolsk%C3%BD-vyn%C3%A1lez-o-predpovediach-umel%C3%BDch-mozgoch-a-2c9dced88bf5#.rugjoj184>

<https://research.googleblog.com/2015/06/inceptionism-going-deeper-into-neural.html>

[https://en.wikipedia.org/wiki/Deep\\_learning](https://en.wikipedia.org/wiki/Deep_learning)

<https://deepdreamgenerator.com/about>

<https://en.wikipedia.org/wiki/DeepDream>

<http://cs.stanford.edu/people/karpathy/deepimagesent/>

<http://spectrum.ieee.org/tech-talk/computing/software/google-translate-gets-a-deep-learning-upgrade>

<http://www.nature.com/news/deep-learning-boosts-google-translate-tool-1.20696>