

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra informačního inženýrství



Diplomová práce

Moderní metody učení neuronových sítí

Bc. Dan Šilhavý

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Dan Šilhavý

Informatika

Název práce

Moderní metody učení neuronových sítí

Název anglicky

Modern neural networks learning methods

Cíle práce

Analýza moderních metod učení neuronových sítí typu deep learning, jejich porovnání s klasickými metodami učení a jejich aplikace na vzorových datech.

Metodika

Prostudování moderních metod deep learning, které se používají pro učení neuronových sítí v aplikacích rozpoznávání obrazů.

Realizace algoritmu deep learning a jeho odzkoušení na zkušebních datech.

Doporučený rozsah práce

60

Klíčová slova

neural networks, deep learning

Doporučené zdroje informací

ENGELBRECHT, A P. *Computational intelligence : an introduction*. Chichester, England ; Hoboken, N.J.: Wiley, 2007. ISBN 0470035617.

I. Goodfellow, Y. Bengio: *Deep Learning*, MIT, 2016

WRÓBLEWSKI, P. *Algoritmy : datové struktury a programovací techniky*. Brno: Computer Press, 2004. ISBN 80-251-0343-9.

Předběžný termín obhajoby

2018/19 LS – PEF

Vedoucí práce

doc. Ing. Arnošt Veselý, CSc.

Garantující pracoviště

Katedra informačního inženýrství

Elektronicky schváleno dne 23. 2. 2018

Ing. Martin Pelikán, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 23. 2. 2018

Ing. Martin Pelikán, Ph.D.

Děkan

V Praze dne 24. 03. 2019

Čestné prohlášení

Prohlašuji, že svou diplomovou práci "Moderní metody učení neuronových sítí" jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu použitých zdrojů na konci práce. Jako autor uvedené diplomové práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušil autorská práva třetích osob.

V Praze dne 28. 3. 2019

Podpis autora _____

Poděkování

Vřele bych rád poděkoval doc. Ing. Arnoštu Veselému, CSc. za vedení, pomoc a odbornou konzultaci při zpracování této diplomové práce. Rád bych také poděkoval autorům neuronových sítí, kteří své ceněné modely zveřejnili; při mé komparativní práci bych se bez mnohých vzorových příkladů neobešel.

Moderní metody učení neuronových sítí

Abstrakt

Práce charakterizuje téma strojového učení pomocí neuronových sítí a deep learning algoritmů. První část práce uceleně vymezuje aktuální metody strojového učení se zaměřením na neuronové sítě a jejich využití v praxi.

Následně práce předkládá srovnání složitosti deep learning algoritmů se standartními metodami strojového učení na modelových programovacích úlohách pro rozpoznávání obrazu.

Praktická část spočívá v návržení a vytvoření webové aplikace využívající deep learning algoritmus k rozpoznání obrazů na zkušebních datech.

Klíčová slova: Strojové učení, neurální sítě, deep learning, programování, algoritmy

Modern neural networks learning methods

Abstract

This thesis elaborates the topic of machine learning through neural networks and deep learning algorithms. The first part of the thesis defines the current methods of machine learning with a focus on neural networks and their use in practice.

Subsequently, the thesis presents a comparison of the complexity of deep learning algorithms with standard machine learning methods in modelling programming tasks for image recognition.

The practical part consists of the design and creation of a web application using the deep learning algorithm to stretch images on the test data.

Keywords: Machine learning, neural networks, deep learning, programming, algorithms

Obsah

1 Úvod.....	14
2 Cíl práce a metodika	15
Část I. Teoretická východiska	
3 Neuron a neuronové sítě	17
3.1 Neuron umělý a biologický	17
3.2 Neuronové sítě	19
3.3 Formalizace neuronu a neuronových sítí	21
3.3 Modely neuronových sítí.....	24
3.3.1 Podle architektury sítě	25
3.3.2 Podle počtu vrstev.....	27
4 Moderní neuronové sítě	29
4.2 Výhody moderních neuronových sítí.....	30
4.3 Aplikace NS	31
4.3.1 Omezení a jejich řešení	31
4.3.2 Přehled konkrétních aplikací	31
4.5 Srovnání moderních a starších neuronových sítí	34
4.5.1 Komparace první - kalibrace.....	34
4.5.2 Komparace druhá – časová složitost.....	34
4.5.3 Výsledky a závěr.....	35
4.5.4 Komparace s konvenčními počítači.....	35
5 Strojové učení neuronových sítí	37
5.1 Klasifikace strojového učení.....	37
5.1.1 Učení s učitelem	37
5.1.2 Učení bez učitele	38
5.1.3 Učení posilováním	39
5.1.4 Semi-supervizované učení.....	40
5.2 Předzpracování dat.....	40
5.3 Generalizace.....	41
5.4 Backpropagation	41

6	Minulost, současnost a budoucnost neuronových sítí	43
6.1	Počátky a první úspěchy	43
6.2	Stagnace a pesimismus	44
6.3	Renesance	44
6.4	Obrat k jiným technologiím	45
6.5	Návrat a velká překvapení	45
6.6	Současnost neuronových sítí	46
6.6.1	Výzkum	46
6.6.2	Aplikace	48
6.6.3	Nedostatky	48
6.7	Budoucnost neuronových sítí	50
Část II. Praktická část		
7	Cíle a metody praktické části	52
7.1	Seznam použitých technologií	52
8	Vlastní řešení	53
	Modul 1 – Detekce objektů z obrazu	56
	Modul 2 – Klasifikace kosatců z Iris datového setu	58
	Modul 3 – Detekce objektů v reálném čase	60
	Modul 4 – Jednoduchá lineární regrese	61
9	Resumé a závěry z praktické části	62
Část III. Diskuze a závěrečné zhodnocení		
10	Závěr	64
11	Použité zdroje	65
12	Přílohy	69
	Příloha I. Aktualizované predikce profesora Brookse	69
	Příloha II. Infografický přehled neuronových sítí	72
	Příloha III. Vybrané zdrojové kódy	73

Seznam obrázků

Obrázek č. 1: Schéma biologického neuronu.....	18
Obrázek č. 2: Plně propojený model neuronové sítě, vlastní tvorba.....	19
Obrázek č. 3: Vztah NS, strojového učení a umělé inteligence.....	20
Obrázek č. 4: Model perceptronu.....	21
Obrázek č.5: Grafy různých aktivačních funkcí.....	22
Obrázek č. 6: Schéma dopředné neuronové sítě.....	23
Obrázek č. 7: Graf architektury dopředné (FF) sítě.....	25
Obrázek č. 8: Graf architektury RNN.....	26
Obrázek č. 9: Graf úplně propojené neuronové sítě.....	26
Obrázek č. 10: Graf Kohohenovy neuronové sítě.....	27
Obrázek č. 11: Graf architektury jednovrstvého perceptronu.....	27
Obrázek č. 12: Graf architektury vícevrstvého perceptronu.....	28
Obrázek č. 13: Výsledky ImageNet soutěže podle % chyby v klasifikaci obrázků.....	30
Obrázek č. 14: Typy strojového učení.....	37
Obrázek č. 15: Schéma učení s učitelem.....	38
Obrázek č. 16: Schéma algoritmu učení bez učitele.....	39
Obrázek č. 17: Schéma algoritmu učení posilováním.....	40
Obrázek č. 18: Statistika počtu vědeckých článků podaných na konferenci.....	47
Obrázek č. 19: Úvodní stránka, 1. část.....	53
Obrázek č. 20: Úvodní stránka, 2. část.....	54
Obrázek č. 21: Stránka s prohlášením o přístupnosti webu.....	55
Obrázek č. 22: Funkční modul 1 – Detekce z obrazů, informační část.....	56
Obrázek č. 23: Funkční modul 1 – Detekce z obrazů, aplikační část.....	57
Obrázek č. 24: Funkční modul 2 – Klasifikace kosatců, informační část.....	58
Obrázek č. 25: Funkční modul 2 – Klasifikace kosatců, aplikační část.....	59
Obrázek č. 29: Funkční modul 2 – Klasifikace kosatců, část analytická.....	59
Obrázek č. 27: Funkční modul 3 – Detekce z kamery, aplikační část.....	60
Obrázek č. 28: Funkční modul 4 – Lineární regrese.....	61

Seznam tabulek

Tabulka č. 1: Přehled klasifikace neuronových sítí	24
Tabulka č. 2: Přehled úspěšných aplikací neuronových sítí	32
Tabulka č. 3: Srovnání výsledků komparace modelů NS	35

Seznam použitých zkratek a pojmů

BN	biologický neuron
CNN / KNS Framework	convolutional neural networks neboli konvoluční neuronové sítě neboli aplikační rámec je softwarová struktura, jež slouží jako podpora při programování a vývoji a organizaci jiných softwarových projektů. Může obsahovat podpůrné programy, knihovny API, podporu pro návrhové vzory nebo doporučené postupy při vývoji.
FPS	frames per second neboli snímky za sekundu
GIT repositář	system správy verzí souborů v repositáři programu, kódu
ImageNet LSVRC	ImageNet Large Scale Visual Recognition Challenge
KNN	k-nearest neighbors algorithm neboli algoritmus k-nejbližších sousedů
MLP	multiplayer perceptron neboli vícevrstevný perceptron
NN / NS	neural networks / neuronové sítě
Open-source	sw s otevřeným zdrojovým kódem, otevřeností je míněna technická i legální dostupnost kódu
RNN / RNS	recurrent neural network / rekurentní neuronové sítě
SDK	software development kit, sada vývojových nástrojů umožňující vytváření aplikací pro jisté softwarové
SVM	support vector machine neboli metoda podpůrných vektorů
UN / AN	umělý neuron / aritificial neuron
UNS / ANN	artificial neural network umělé neuronové sítě
Wiki	webové stránky (nebo obecněji hypertextové dokumenty), které umožňují uživatelům přidávat obsah podobně jako v internetových diskusích, ale navíc jim umožňují měnit stávající obsah.

1 Úvod

Jsou to právě neuronové sítě, které hrají ústřední roli v moderním vývoji umělé inteligence, která za poslední desetiletí slaví nepředvídané úspěchy. Od autonomních vozů přes rozvoj osobní asistence nebo vítězství v komplexních hrách typu go nebo shogi je progres umělé inteligence zapříčiněn rozvojem hlubokých neuronových sítí, které využívají velké objemy dat a vysoký výpočetní výkon.

Vhodné je zde zmínit i příčinu dosavadního velkého zájmu a nadšení z umělé inteligence, a to nejen nadšení odborné komunity ale i široké veřejnosti. Stručně by se dalo říci, že ještě na přelomu tisíciletí velkým pokrokům v umělé inteligenci mnoho lidí nevěřilo; historie tomu nenasvědčovala.

Od 50. se výzkum umělé inteligence provozoval především v UK, USA, Rusku a později v Japonsku. Státy investovaly mnoho svých veřejných zdrojů, nicméně k očekávaným výsledkům se dospět nikde nepodařilo a obor, který měl zprvopočátku ambice stát se samostatnou vědou, se potácel v periodách velkých očekávání a následných zklamání.

Pozitivního překvapení se vědci nicméně dočkali, a to díky neuronovým sítím. V období od roku 2012 dochází k nečekaným vědeckým a následně inženýrským průlomům v oblasti rozeznávání objektů z obrazů jako je například psané písmo nebo rozeznávání SPZ značek. A od té doby se úspěchy neuronových sítí jen hromadí, vědeckých prací bylo v absolutních počtech na toto téma v minulém roce více než kdykoliv jindy a neuronové sítě, o které ještě koncem 90. let byl nevalný zájem, mají vzletnou budoucnost před sebou.

2 Cíl práce a metodika

Cílem práce je podrobné zpracování tématu neuronových sítí v rámci strojového učení. První část práce uceleně vymezuje algoritmy neuronových sítí a strojového učení, historii spolu s aktuálním vývojem a důrazem na nejmodernější metody detekce objektů z obrazu.

V kapitole 4 práce předkládá srovnání složitosti moderních deep learning algoritmů se staršími metodami strojového učení, a to na modelových úlohách pro rozpoznávání obrazu.

Ze znalostí teoretické části vychází zpracování části praktické, jejímž cílem je navržení a vytvoření webové aplikace využívající deep learning algoritmus k detekci objektů na zkušebních obrazových datech. Záměrem je zde prozkoumat a otestovat úspěšné algoritmy moderních neuronových sítí.

Pro dosažení stanovených cílů je studium jednak algoritmů neuronových sítí ale také i ostatních typů strojového učení.

Výchozí metodou ke zpracování praktické části práce je především programování ve frameworku Tensorflow.js a dále pak práce v jazyce PHP, HTML a CSS. Návrh vyvíjeného programu vychází z autorových znalostí v oblasti softwarového inženýrství a teoretické části této diplomové práce.

Část I.
Teoretická východiska

V této části práce je postupně charakterizována teorie potřebná k pochopení metody detekce objektů v obrazech pomocí moderních neuronových sítí.

3 Neuron a neuronové sítě

V této kapitole jsou nejdříve širěji vysvětleny a charakterizovány základní pojmy neuronových sítí (dále také jako NS), které jsou následně konkretizovány v podkapitole 3.4 Formalizace neuronových sítí a se kterými operuje kapitola 5.


3.1 Neuron umělý a biologický

Uvažujeme-li neuron v kontextu umělé inteligence, máme primárně na mysli neuron umělý (UN), tedy neuron, který je matematickým modelem, respektive matematickou funkcí simulující neuron biologický (Engelbrecht, 2007, s. 5). Blížeji se neuronem (UN) zabývá kapitola 3.4 Formalizace neuronové sítě.

Biologický neuron

Základní stavební bloky biologických nervových systémů jsou nervové buňky, označované jako neurony. Jak je znázorněno na obrázku č. 1, neuron se stává z buněčného těla, dendritů a axonu. Neurony jsou masivně propojené, kde je propojení mezi axonem jednoho neuronu a dendritem jiného neuronu. Toto spojení se nazývá synapse. Signály se šíří z dendritů přes tělo buňky k axonu; odkud jsou signály šířeny do všech připojených dendritů. Zároveň platí, že signál je přenášen do axonu neuronu pouze tehdy, když buňka se aktivuje. Neuron může buď inhibovat nebo excitovat signál.

Obrázek č. 1: Schéma biologického neuronu



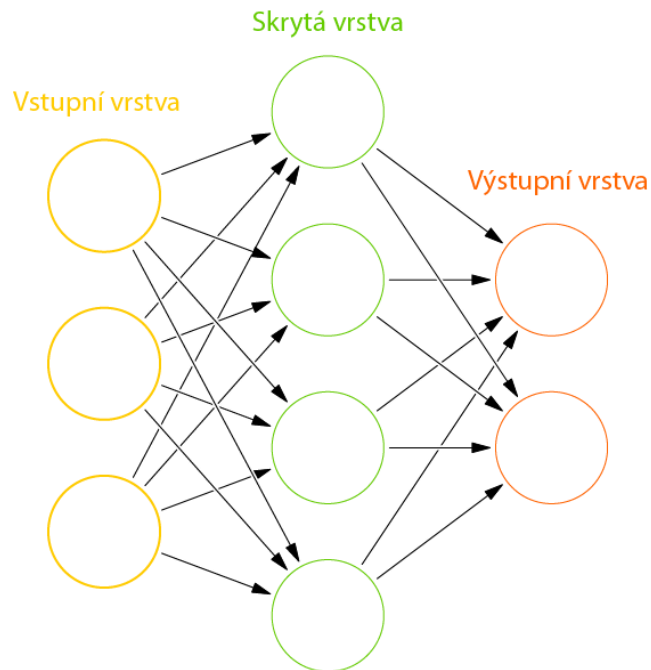
Zdroj: Engelbrecht, 2007, s. 6

Inspirace biologickým neuronem zjevná, nicméně tím ta paralela více méně končí a analogie umělých neuronů s biologickými neurony nebo neurovědou může být zavádějící. Lidský mozek totiž obsahuje přibližně 100 miliard neuronů operujících paralelně (Long a Gupta, 2008, s. 9-10), zatímco umělé neurony jsou matematické funkce implementované na více či méně sériových počítačích. Výzkum v oblasti neuronových sítí je také většinou veden vývojem v oblasti inženýrství a matematiky nežli neurovědou nebo biologií (Goodfellow a kol., 2016, s. 169)

3.2 Neuronové sítě

Neuronová síť je kombinací umělých neuronů, tedy matematických funkcí, které jsou seskupeny do vrstev. Jak ukazuje obrázek č. 2 neurony jsou propojeny s dalšími neurony, kterým předávají data. V základních modelech neuronových sítí jsou spojeny tak, že každý neuron je spojen s každým neuronem v následující vrstvě. Tvarů NS je nicméně mnoho a spojení mezi neurony může mít různé podoby, které dále rozebírá kapitola 4) Modely NS.

Obrázek č. 2: Plně propojený model neuronové sítě, vlastní tvorba.

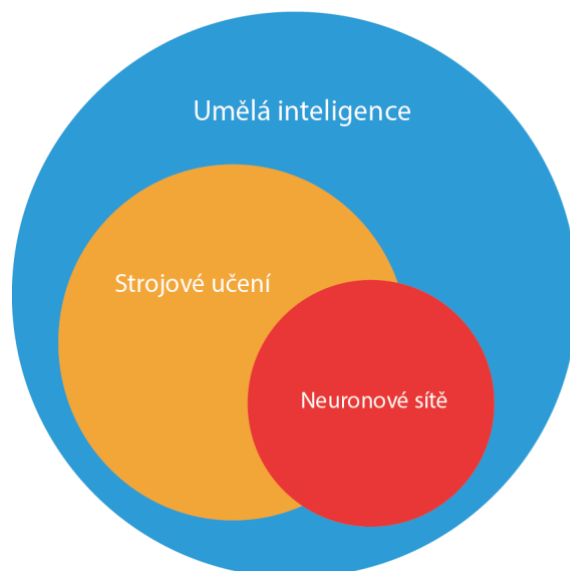


Zdroj: Engelbrecht, 2007, s. 7. vlastní tvorba

Z obrázku výše je možné vidět, že některé vrstvy zpracovávají původní vstupní data, zatímco některá procesní data jsou přijímána z jiných neuronů. Existuje mnoho druhů NS, pro všechny však platí, že záměrem je správný výsledek na výstupní vrstvě.

Neuronové sítě jsou dnes primárně využívány v rámci umělé inteligence a od roku 2012 dominují modelům strojového učení. Ústřední roli ale nehrají jen v obalasti strojového učení, proto je v obrázku č. 3 vyjádřen vztah mezi NN, strojovým učením a umělou inteligencí.

Obrázek č. 3: Vztah NS, strojového učení a umělé inteligence



Zdroj: Wehle, 2017, s. 2-4. Vlastní zpracování

Část NS nespádající do oblasti strojového učení je tvořena převážně teorií o neuropočítačích, které se snaží simulovat funkce potažmo inteligenci lidského mozku. První úspěšné realizace byly v 50. letech, autorem byl americký neurovědec Marvin Minsky a dále pak také v 80. letech (Carver, 1990). Více je popsáno v následující kapitole 3.1.

3.3 Formalizace neuronu a neuronových sítí

Tato kapitola konkretizuje obecný popis zmíněných termínů v kapitole 3.1 a 3.2

3.4.1 První formulace neuronu

Autoři W. S. McCulloch a W. Pitts, rok 1943.

$$f(\xi) = \sum_0^n w_n \cdot x_n \quad (3.1)$$

Vstupem (pro model) jsou binární hodnoty, které jsou napojené na neuron. Samotný neuron, tj. v tělo neuronu pak vypočítává sumu vstupních hodnot, které jsou násobené váhou w_n . Tato suma je následně porovnávána s nastaveným prahem θ


$$y = \begin{cases} 1 & f(\xi) \geq \theta \\ 0 & f(\xi) < \theta \end{cases} \quad (3.2.)$$

Kromě první matematické formulace neuronu také autoři ve své práci popisují jak, jednotlivé neurony v mozku jednotlivě komunikují a zároveň demonstrovali funkčnost jejich modelu pro běžné logické opera, například AND nebo OR či NOT.

3.4.2 Perceptron, nový model neuronu

Autor: Frank Rosenblatt (1954)

Obrázek č. 4: Model perceptronu




Zdroj: Veselý, 2012. vlastní tvorba.

Vstupem do modelu je zde n hran ohodnocených váhami. Jeden vstup je tzv. biasový, který je používán pro úpravu aktivační funkce. Každý vstup je vynásoben jeho vahou a následně je dělána suma. Pokud je součet sumy po odečtení prahu kladný, bude výstupem perceptronu 1, pokud bude záporný tak výstupem je 0. Každý neuron má počet vah rovný počtu neuronů v předchozí vrstvě.

Aktivační funkce (angl. *activation function*) je taková funkce, která je použita na sumu ohodnocení vstupních hran vynásobených s jejich váhami. Mezi základní aktivační funkce patří jednotkový skok (angl. *hardlim*), funkce signum (angl. *hardlims*), sigmoidální funkce (angl. *logsig*) a funkce lineární (angl. *purelin*). Výběr optimální aktivační funkce má vliv na proces učení neuronové sítě, který popisuje kapitola 5. Obrázek č. 5 znázorňuje grafy různých aktivačních funkcí.

Obrázek č.5: Grafy různých aktivačních funkcí




Zdroj: <https://ujjwalkarn.me/2016/08/09/quick-intro-neural-networks/>

3.4.3 Neuronové sítě

Neuronové sítě kombinují jednotlivé neurony (někdy také jako uzly, v angl. *node*), které jsou uspořádány do tzv. vrstev, viz obrázek č. 6. Více neuronů znamená i více aktivačních funkcí.

První neuronovou sítí byla tzv. dopředná neuronová síť (angl. *feedforward*), viz obrázek č. 6. Tento model obsahuje neurony uspořádané do 3 vrstev. Neurony ze sousedních vrstev mají mezi sebou spoje (hrany) a všechny tyto hrany mají váhu, která je k nim přiřazena.

Obrázek č. 6: Schéma dopředné neuronové sítě



Zdroj: <https://ujjwalkarn.me/2016/08/09/quick-intro-neural-networks/>

- **Vstupní neurony** - poskytují informace z vnějšího světa do sítě a jsou společně označovány jako „vstupní vrstva“. V žádném ze vstupních uzlů se neprovádí žádné výpočty - informace předávají pouze skrytým uzlům.
- **Skryté uzly** - nemají přímé spojení s okolním světem (jsou tedy tzv. „skryté“). Provádí výpočty a přenášejí informace ze vstupních uzlů do výstupních uzlů. Zatímco dopředná síť má pouze jednu vstupní vrstvu a jedinou výstupní vrstvu, může mít nula nebo více skrytých vrstev.
- **Výstupní uzly** - jsou souhrnně označovány jako „výstupní vrstva“ a jsou odpovědné za výpočty a přenos informací ze sítě do okolního světa.

V dopředné síti se informace pohybují pouze jedním směrem, tj. dopředu. Ze vstupních uzlů, skrze skryté uzly (pokud existují) do výstupních uzlů. V síti neexistují žádné cykly ani smyčky, nicméně tato vlastnost dopředných sítí se liší od rekurentních neuronových sítí, které vymezuje následující kapitola 3.3.

Výhody neuronových sítí

Mezi velké výhody neuronových sítí patří paralelizmus při vlastním výpočtu. Neuronové sítě se používají na úlohy směřované do oblasti klasifikace, aproximace a predikce. Svůj prapůvod mají umělé neuronové sítě v biologické oblasti.

3.3 Modely neuronových sítí

Existuje mnoho odlišných neuronových sítí; Kriesel (2007, s. 39) uvádí 2 typy rozlišení, a to sice podle architektury sítě a podle typu učícího algoritmu. Hagan a kol. (2014, s. 29) přidávají rozlišení podle počtu vrstev v síti a také podle způsobu nastavování vah v NS. Pro lepší přehled jednotlivých typů NS byla zpracována tabulka č.2. Následující podkapitoly tuto tabulku konkretizují a uvádějí příklady modelů NS.

Tabulka č. 1: Přehled klasifikace neuronových sítí

Klasifikace podle	Jednotlivé typy NS	Charakteristika
Architektury (propojení neuronů)	I. Dopředné (FF) II. Rekurentní (RNN)	Dopředné: Data prostupují síť jedním směrem. Rekurentní: Data mohou prostupovat síť více směry a tvořit cykly.
Počtu skrytých vrstev	I. Jednovrstvé II. Vícevrstvé	Vícevrstvé sítě mají 2 a více skrytých vrstev.
Typu nastavení vah	I. Fixní II. Adaptivní	Fixní: Váhy jsou a priori nastaveny a nemění se. Adaptivní: Váhy se mění v průběhu trénování.
Stylu učení	I. Deterministické II. Stochastické	Deterministické: například Backpropagation Stochastické: náhodne nastavování vah
Typu vstupních dat	I. Analogické II. Binární vstupy	Analogické NS mají vstupní data ve formě reálných čísel. Binární NS mají všechny vstupní data ve tvaru jedniček a nul.

Typu paměti	II. Statické III. Dynamické	Statické: Nemají paměť resp. výstup pro danou epochu závisí pouze na vstupu z dané epochy. Např. dopředné sítě Dynamické: Výstup započítává data i z minulých epoch. Např. rekurentní sítě
-------------	--------------------------------	---

Zdroj: Kriesel, 2007, s. 39. Hagan a kol., 2014, s. 29. Vlastní zpracování


3.3.1 Podle architektury sítě

Architekturou neuronové sítě je rozuměn způsob napojení jednotlivých neuronů na sebe. Nejběžnějším takovým napojením co do praktické aplikace je tzv. dopředná neuronová síť (ang. *feedforward*, dále také *FFN*).

Dopředná neuronová síť

Pro dopřednou neuronovou síť platí, že všechny neurony jsou plně propojeny, tj. každý neuron je propojený s každým neuronem v následující vrstvě a zároveň veškerá data mohou prostupovat sítí pouze dopředně, narozdíl od rekurentních NS, kde mohou být prostupovat sítí i zpětně. Ve většině případech je dopředná síť trénována za pomoci backpropagation algoritmu.

Obrázek č. 7: Graf architektury




Zdroj: The Medium, 2017.

V předcházejícím a následujících obrázcích v kapitole Klasifikace neuronových sítí podle jejich architektury představují žluté kruhy vstupní neurony. Zelené kruhy pak představují skryté neurony, kterých v případě DFF může být ve více vrstvách. Červené kruhy představují výstupní neurony.

Rekurentní neuronová síť

Rekurentní neuronová síť (dále také jako „RNN“) je, na rozdíl od FFN, neuronová síť, která umožňuje obousměrný tok dat. Síť mezi připojenými jednotkami tvoří řízený cyklus. Taková síť umožňuje dynamické chování v čase. Často se tedy jedná o poměrně komplexní a výpočetně náročné sítě. Vhodné je také zmínit, že rekurentní neuronová síť je schopna použít svou vnitřní paměť pro zpracování libovolné sekvence vstupů. Tato neuronová síť je oblíbenou volbou pro úkoly, jako je rozpoznávání řeči.

Obrázek č. 8: Graf architektury RNN




Modré kruhy zde představují rekurentní neurony; rekurentních vstupů zde může být i více

Zdroj: The Medium, 2017

Zcela propojená neuronová síť

Někdy také kompletně propojená (angl. *fully connected*) síť je specifická tím, že každý neuron jedné vrstvy musí být propojen s každým neuronem vrstvy následující. Může dojít i k situaci, kdy je každý neuron propojený se všemi ostatními. Příkladem může být jakákoliv síť s jakýmkoliv počtem vrstev, jednoduchý příklad je vidět na obrázku níže.

Obrázek č. 9: Graf úplně propojené neuronové sítě




Zdroj: The Medium, 2017

Kohonenova neuronová síť

Jedná se o tzv. samoorganizující se NS, kterou vynalezl Teuvo Kohonen. Má úplné neuronové propojení a specifická je tím, že využívá konkurenční algoritmus učení na rozdíl od algoritmu korekce chyb (Kohonen, 2013, s. 53). Ideálně je pro vizualizaci vysoko rozměrných dat.

Obrázek č. 10: Graf Kohonenovy neuronové sítě



Zdroj: The Medium, 2017


3.3.2 Podle počtu vrstev

Rozlišení podle počtu skrytých vrstev nejlépe demonstrují jednotlivé varianty perceptronů (Hagan a kol., 2014, s. 29). Vícevrstvé sítě jsou také tzv. hluboké sítě (angl. *deep neural networks*), které popisuje kapitola následující.

Jednovrstevný perceptron

Je modelovým příkladem dopředné neuronové sítě. Jedná se o nejjednodušší a nejstarší model umělého neuronu, který byl vyvinut Frankem Rosenblattem, kognitivním psychologem, v létě 1957. Funkce perceptronu spočívá pouze v příjmu vstupů a výpočtu výstupu za pomoci vah a následně aktivační funkce.

Obrázek č. 11: Graf architektury jednovrstevného perceptronu




Zdroj: The Medium, 2017

Vícevrstevný perceptron

Jednovrstevný perceptron byl ve své funkci velmi omezený, navrhnout byl tedy perceptron vícevrstevný, viz obrázek č. (angl. *multilayer perceptron* zkráceně pak *MLP*), který byl využíván v 80. letech pro automatizaci rozpoznávání řeči (angl. *speech recognition*) a počítačového vidění. V 90. letech byl postupně nahrazován metodou podpůrných vektorů (angl. *support vector machine*).

Obrázek č. 12: Graf architektury vícevrstvého perceptronu



Dostupné z: The Medium, 2017

Hluboké (angl. *deep feed forward*) sítě jsou modernější variantou dopředných neuronových sítí. DFF sítě byly ještě v 90. letech velmi náročné na výpočetní sílu a tudíž nepraktické; dnes jsou naopak díky přesnější zpětné propagaci chyby výhodnější. Speciální případ neuronové sítě je tzv. konvoluční neuronová síť (dále také jako CNN), která je hojně využívána k detekci objektů na obrazech, tou se zabývá následující kapitola Moderní neuronové sítě.

4 Moderní neuronové sítě


Dle Russela a kol. (2010) lze v historii definovat několik stupňů vývoje umělé inteligence potažmo neuronových sítí. Moderní neuronové sítě Peter Nervi (Russel a kol., 2010) vymezuje rozvojem **hlubokých neuronových sítí nad velkými datovými sety**. Pro přesnost vymezení je ještě uvedena definice Lecuna a kol. (2015): Hlubokými NS (angl. *deep neural networks*) se rozumí takové NS, které mají 2 a více skrytých vrstev. Hluboké učení (angl. *deep learning*) je pak takové učení, které probíhá v rámci hlubokých neuronových sítí.

Nicméně principy hlubokých neuronových sítí a jejich učení nejsou nic nového; obecné myšlenky existují už od 40. let minulého století (Engelbrecht, 2007, s. 11-12). A proč se tedy začali hojně využívat až o 60 let později? Krátce řečeno, *deep learning* bylo takřka zapomenuto. To bylo provázáno i tím, že několikrát změnilo své pojmenování, dříve se užívalo například „hierarchical learning“ nebo „deep structured learning“ a obdobně (Goodfellow, 2006, s. 13).

Nicméně důležitým prvkem byl i technologický pokrok, větší výpočetní výkon a dostupnost velkých datových sad napomohla obrodě hlubokého učení.

Chronologicky pak měli moderní NS boom v období let 2006 až 2012, kdy jednak vznikaly nové modely hlubokých NS a rychlé učící algoritmy (Hinton a kol., 2006; Youshua a kol., 2007), ale také došlo k překvapivým vítězstvím neuronových sítí v mezinárodních soutěžích typu ImageNet Large Scale Visual Recognition Challenge (dále jen *ImageNet LSVRC*). Tato vítězství byla pro odbornou veřejnost velmi překvapivá, a to obzvláště i v následujících letech, viz obrázek č. 13.

Obrázek č. 13: Výsledky ImageNet soutěže podle % chyby v klasifikaci obrázků



Zdroj: Zitzewitz, 2007

Zajímavé na obrázku č. 13 je také to, že modře jsou vyznačeny metody hluboko učení, zeleně je vyznačen nejlepší výsledek metod počítačového vidění (nikoliv neuronových sítí) a červeně je vyznačen průměrné skóre člověka. Jak je i hezky vidět na obrázku od roku 2012 je hluboké učení znovu na scéně a dá se říci, že strojovému učení dnes dominuje.

4.1 Výhody moderních neuronových sítí

Hluboké učení je založeno na filosofii konektivismu (angl. connectionism): zatímco individuální biologický neuron a nebo individuální umělý neuron (případně také *feature*) v modelu strojového učení není inteligentní, velká populace těchto neinteligentních neuronů mohou být inteligentní respektive vykazovat inteligentní chování.

Je opravdu důležité zdůraznit skutečnost, že počet neuronů v hlubokém učení musí být velký. Totiž jedním z klíčových faktorů vedoucích ke zlepšení přesnosti neuronových sítí a možnosti řešit složitější úkoly, mezi 80. léty a dnes, je **dramatický nárůst velikosti používaných sítí**. Za poslední tři desetiletí narůstaly velikosti hlubokých sítí exponenciálně. Nicméně stále je pravdou, že umělé neuronové sítě mají ještě menší počet neuronů než běžné nervové systémy hmyzu (Goodfellow, s. 445).

Modelů neuronových sítí je nespočet, proto je zde uveden výčet demonstrativní: Odlišením podle architektury sítě lze rozeznat například: Generative Adversarial sítě, Deep Belief sítě, auto-enkóдеры, Gated Recurrent sítě a dále pak například sítě Modulární.

4.2 Aplikace hlubokých neuronových sítí

Nejúspěšnějšími oblastmi, ve kterých se deep learning využívá, jsou:

- Rozeznávání řeči (angl. *speech recognition*),
- Počítačové vidění (angl. *computer vision*) a
- Zpracovávání přirozeného jazyka (angl. *natural language processing*)

Nicméně hluboké učení je dosti výpočetně a paměťově náročné a v úspěšné implementaci má několik omezení.

4.2.1 Omezení a jejich řešení

Dnes je aplikace hlubokého učení usnadněná výkonností grafických čipů (dále jen GPU), které v komparaci s centrální procesní jednotkou (dále jen CPU) značně napomáhají zrychlení fungování hlubokých neuronových sítí. Pro náročné úlohy se využívá několik počítačů zároveň, buď metodou paralelní distribuce dat nebo přímo distribuce částí modelu tak, že každý počítač zpracovává jinou část modelu (Goodfellow, 446-448).

Pro komerční využití se naopak využívá komprese modelu, tj. zmenšování časové a paměťové náročnosti běhu a specificky pak učení modelu. Případně je možné využít stroje přímo vyráběné pro hluboké učení, v současné době jsou typické stroje s FPGA (programovatelnými hradlovými poli, angl. *Field Programmable Gate Array*), které používají ALU jednotky nepracující s operandy v plovoucí řádové čárce ale naopak s celočíselnou (angl. *fixed point*) aritmetikou. (Goodfellow, s. 450-454)

4.2.2 Přehled konkrétních aplikací

Níže v tabulce č. 2 je uveden výčet úspěšných aplikací hlubokých neuronových sítí kategorizovaný podle oblastí respektive průmyslů nebo sektorů ekonomiky.

Tabulka č. 2: Přehled úspěšných aplikací neuronových sítí

Oblast*	Konkrétní užití	Organizace nebo projekt
Medicína	Predikce zdravotních problémů, např. vysoký krevní tlak skrze chytré hodinky	CardioGram
	Automatická segmentace rakovinového tumoru	InnerEye
Právo	Segmentace vhodných podkladových materiálů pro zadaný právní spor	EverLaw
Osobní asistence	Poskytování informací, konverzace, čtení knih, nastavování budíku, vytváření seznamů úkolů a další	BMW Assistant, Apple – Siri, Amazon – Alexa, Google Assistant, MS – Cortana, Alibaba – AliGenie
Doprava	Autonomie aut, dronů, letadel.	Tesla, ShieldAI a ZipLine projekt rozvozu krve
Zemědělství	Detekce a monitoring závadných plodin nebo půdy	Blue River Technologies – See & Spray. PEAT - Plantix
	Sběr plodin	Harvest CROO Robotics
Grafický průmysl	Texturování a designování digitálních materiálů (substance designing)	Adobe - Substance designer
	Automatická úprava obrázků: deNoising, image uprezing, motion capture: identification of moving bodies and rotoscoping,	
	Tvorba, transformace (Style Transfer - CycleGAN) nebo dokreslování (Image2Image) obrázků či videí.	Runway – RunwayApp.io DeepArt.io (Obrázky nebo videa)
	Tvorba deswebových stránek	The Grid – Grid.io
Sport	Couchování fotbalových hráčů a trenérů (analýza efektivity)	Disney - DisneyResearch

	pohybování hráčů na hřišti)	
Hudba	Asistence při tvorbě hudby nebo samotná tvorba samplů hudby	Amper Music - Amper Scorenebo Jukedeck (Model ADA), https://arxiv.org/abs/1806.10474
	Doporučování hudby	Spotify, Goole Music a další
Překladatelství	Překlad z textu nebo přímo hlasu	Google Translate, Facebook Post Translation, Deep L Translator, Cortana a další
	Překlad z hlasu do titulek videa	Google YouTube, Vimeo
Komunikace	Antispam	Re:scam, Google Gmail, Foursquare zprávy
Herní průmysl	Asistence při hraní (statistické kalkulace) pro hru šachy a dáma	Advanced Chess
	Inteligentní agenti (protihráči) ve hře šachy, go, Dota 2, Starcraft a dalších hrách	DeepMind - AlphaGo Zero – Šachy, Go, Shogi AlphaStar – Starcraft OpenAI – Dota 2
Finančnictví	Predikce cen	Perfect price, Navetti PricePoint
Marketing	Doporučení zboží	Amazon Store, Google Play
	Segmentace zákazníků	Google Adds, Facebook
	Generování marketingových obsahů (článků, statusů, ...)	Automated Insights – Wordsmith Narrative Science - Quill
	Email Marketing,	Zeta - ZetaHub
	Automatizace analýzy dat	Adext Corp – Adext.ai

*Oblastí je myšlen průmysl případně sektor ekonomiky nebo (XOR) znalostní oblast

Zdroj: kombinace mnoha internetových zdrojů, viz kapitola 10. Použité zdroje. Vlastní zpracování

4.3 Srovnání moderních a starších neuronových sítí

Kritériem komparace složitosti moderních a starších NS je jejich výpočetní náročnost, a to primárně časová tedy asymptotická. Náročnost na paměť tedy operační náročnost je dnes spíše zanedbatelná (Wróblewski, 2015, s. 52-53).

4.3.1 Komparace první – kalibrace

Výzkum Chuana Guo a kol. (2017), porovnávající kalibrace NS, zjišťuje, že moderní neuronové sítě například ResNet z roku 2016 jsou **hůře kalibrovány** než staré NS, například model LeNet z roku 1998. V práci nicméně podávají stručný popis, jak moderní NS lépe kalibrovat.

Kalibrováním se zde rozumí míra nesprávně předpovídaných pravděpodobností vzhledem k správným pravděpodobnostem (angl. *true probabilities*).

4.3.2 Komparace druhá – časová složitost

Testovací hardware

Srovnání probíhalo na desktopovém počítači se čtyř jádrovým procesorem Intel Core i5 verze 6500 s frekvencí jednoho jádra 3.2GHz a celkovou operační pamětí 8 GB. Každý blok testů byl proveden 10x, ze vzorku se následně vypočítal aritmetický průměr.

Testované modely NS

Vybrány byly 4 reprezentativní sítě pro detekci objektů z obrázků a to sice:

- **LeNet** z roku 1988¹
- **AlexNet** z roku 2012²
- **GoogleNet – Inception** z roku 2014³
- **ResNet** z roku 2016⁴

Hloubka sítí a její konfigurace je specifická každé z nich, nicméně podrobné charakteristiky jsou zpracované v odkazech pod čarou. Datový set je známý ImageNet.

¹ Charakteristika modelů: LeNet: <https://engmrk.com/lenet-5-a-classic-cnn-architecture>

² AlexNet: <http://ethereon.github.io/netscope/#/preset/alexnet>

³ GoogleNet – Inception: <https://leonardoaraujosantos.gitbooks.io/artificial-intelligence/content/googlenet.html>

⁴ ResNet: <https://towardsdatascience.com/implementing-a-resnet-model-from-scratch-971be7193718>

4.3.3 Výsledky a závěr

Tabulka č. 3: Srovnání výsledků komparace modelů NS

Model	Rok	Počet vrstev	Rychlost [ms]	Chybovost [%]
LeNet v5	1988	7	28.26	40,6
AlexNet	2012	8	29.56	15,3
GoogleNet - Inception	2014	22	73.2	5,1
ResNet 200	2016	200	342.12	3,6

Zdroj: vlastní tvorba.

Z tabuly č. 3 je vidět, že moderní neuronové sítě s vyšším počtem vrstev jsou pomalejší. Zároveň je však vidět, že chybovost modelu s počtem vrstev klesá; optimální řešení je tedy otázkou výběru a následné kalibrace vhodného modelu podle zadaného cíle řešení.

Zároveň je zde vhodné zmínit i komparaci neuronových sítí a konvenčních, von Neumann, počítačových systémů.

4.3.4 Komparace s konvenčními počítači

Paralelní zpracování

Jednou z hlavních výhod neuronové sítě je její schopnost provádět mnoho věcí zároveň. U tradičních počítačů je zpracovávání sekvenční; pochopitelně myšlenka realizace výpočtů ve více vláknech (angl. *threading*) je velice efektivní, nicméně procesy probíhají z principu sekvenčně.

Umělá neuronová síť je na druhé straně je od počátku navržena paralelně. Bez velké modifikace jde proces v NS přes jeden nebo více procesorů von Neumann architektury. Nevýhodou je, že procesory musí být pro neuronovou síť speciálně navržené.

Programovatelnost (angl. *self-programming*)

Počítače von Neumannovi architektury jsou programovatelné a je možné je učit, nicméně vždy tomu tak je pouze sekvenčně. Naopak neuronové sítě se při učení neustále přizpůsobují skutečným změnám vlastního kódu a mohou v principu „programovat sami sebe“.

Rychlost

Rychlost každého typu počítače závisí na různých aspektech použitého procesoru a nelze tedy určit absolutního vítěze v této kategorii. Stroje von Neumannovi architektury vyžadují buď velké procesory, nebo implementaci paralelních procesorů, které jsou náchylné k chybám, zatímco neuronové sítě vyžadují použití více čipů vytvořených speciálně pro ně (Stanford Computer Science, 2019).

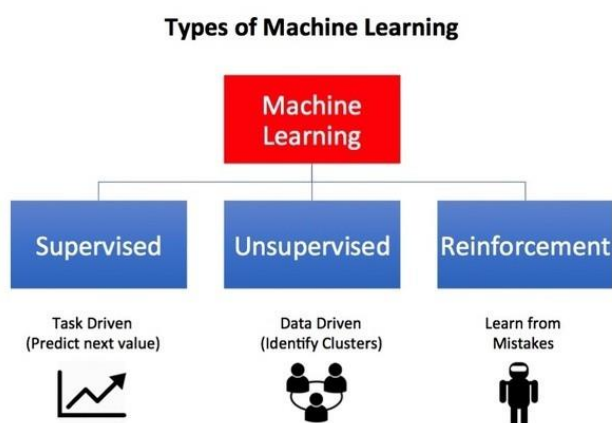
5 Strojové učení neuronových sítí

Strojové učení je užitečný nástroj pro modelování problémů, které je obtížné přesně formulovat. Je alternativou ke klasickým počítačovým programům, které jsou psány výhradně ručně k provedení úkolu. U strojového učení je naopak část lidského příspěvku nahrazena algoritmem učení. Jelikož časem narůstá dostupnost výpočetní kapacity a dat, strojové učení se v průběhu let stalo stále praktičtějším a dnes již téměř všudypřítomným (Goodfellow a kol., 2016, s. 2).

5.1 Klasifikace strojového učení

Dnes je možné stroje a tudíž i neuronové sítě učit 3 následujícími metodami.

Obrázek č. 14: Typy strojového učení



Zdroj: Machine Learning. The basics [online]. 2018 [cit. 2019-02-23].

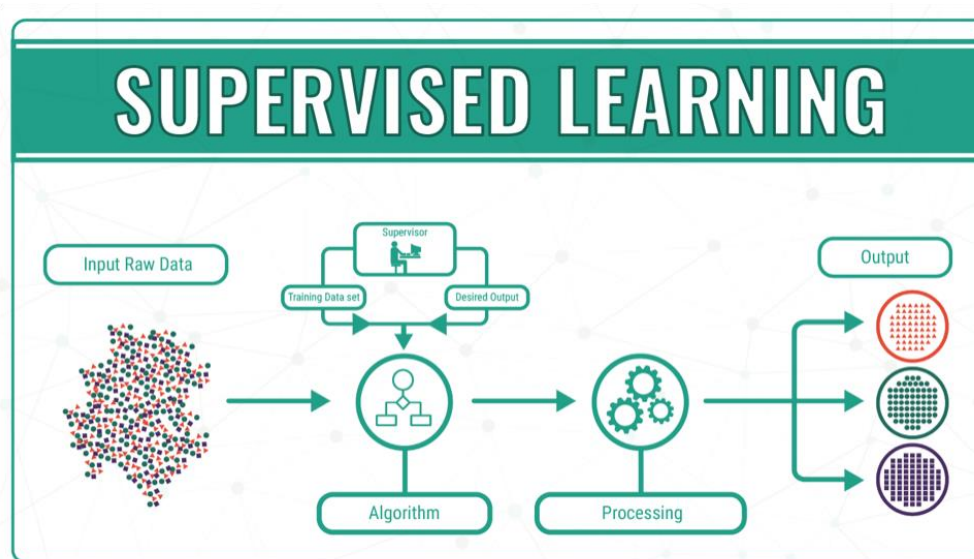
Dostupné z: <https://towardsdatascience.com/machine-learning-d247a9420dab>

5.1.1 Učení s učitelem

Trénování neuronové sítě pomocí učitele (*supervised learning*) je specifické tím, že je nutné mít trénovací množinu známých vstupů a korespondující množinu správných respektive požadovaných výstupů NS. Nejdříve probíhá proces trénování s tím, že každý vypočtený výsledek neuronu je porovnán se správným řešením. Podle rozdílu jsou pak změněny váhy sítě.

Algoritmus má za cíl změnit váhy takovým způsobem, aby síť po natrénování nejen připojila k vzorovému vstupu i požadovaný výstup, ale aby také do neznámému vstupu dodala vhodný výsledek, tedy aby byla schopna generalizovat ze známých hodnot na neznámé. Algoritmus je popsán na obrázku níže.

Obrázek č. 15: Schéma učení s učitelem



Zdroj: Machine learning explained [online]. 2018 [cit. 2019-02-23].

Dostupné z: <https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/>

V současné době představuje učení s učitelem představuje většinu strojového učení. Takovéto algoritmy se běžné použití jsou pro klasifikační a regresní úlohy (Alpaydin. 2010. s. 9). Typickým zástupcem učení s učitelem je backpropagation (BigData.com, 2018).

5.1.2 Učení bez učitele

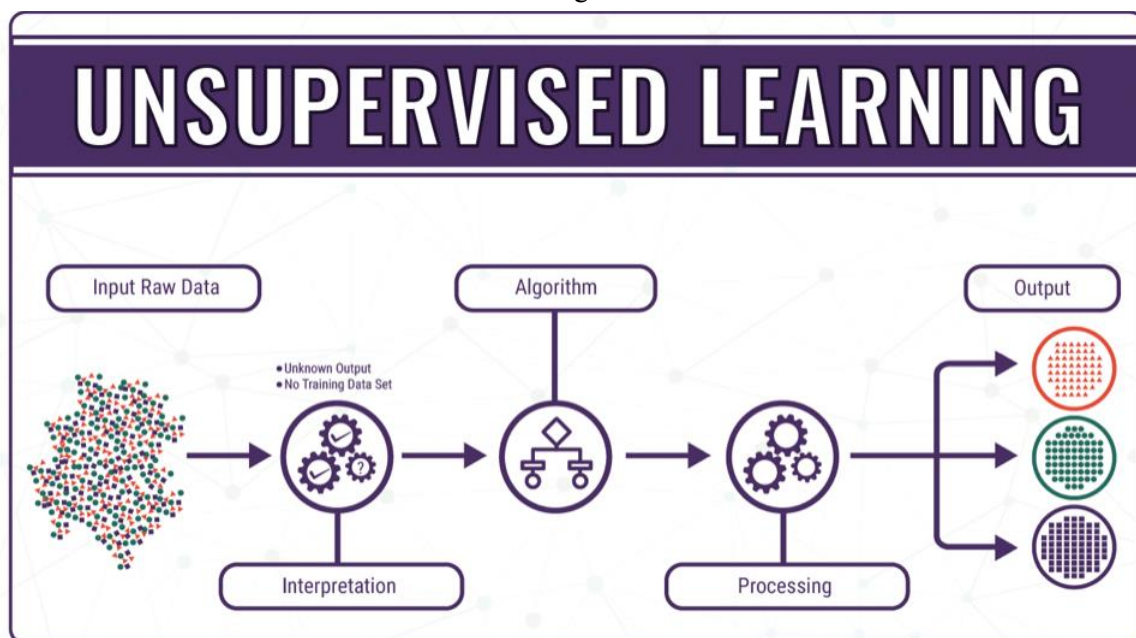
Tento typ učení také někdy označován jako učení bez dozoru (angl. unsupervised learning) není tak rozšířený a často používaný jako učení s učitelem. Konkrétně byl tento koncept dosud používán pouze v omezeném množství aplikací, nicméně navzdory tomu tvoří tato metodika pravděpodobně budoucnost strojového učení a jeho možností.

Během procesu učení bez dozoru nemá algoritmus přístup ke správným ani očekávaným výsledkům. Veškerá data se kterými pracuje jsou neoznačená (angl. unlabeled)

a účelem je tedy nejdříve data prozkoumat a najít v nich strukturu. Algoritmus následně podle rozpoznaných podobností ve struktuře vytváří datové shluky.

Tato technika učení funguje dobře pro klastrování (angl. *clustering*), může například identifikovat segmenty zákazníků s podobnými atributy, s nimiž lze pak v marketingových kampaních zacházet obdobně. Nebo může najít primární vlastnosti, které od sebe oddělují zákaznické segmenty. Tyto algoritmy se také používají k segmentování textových témat, nebo vytváření doporučení, respektive k nalézání podobností.

Obrázek č. 16: Schéma algoritmu učení bez učitele



Zdroj: Machine learning explained [online]. 2018 [cit. 2019-02-23].

Dostupné z: www.bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/

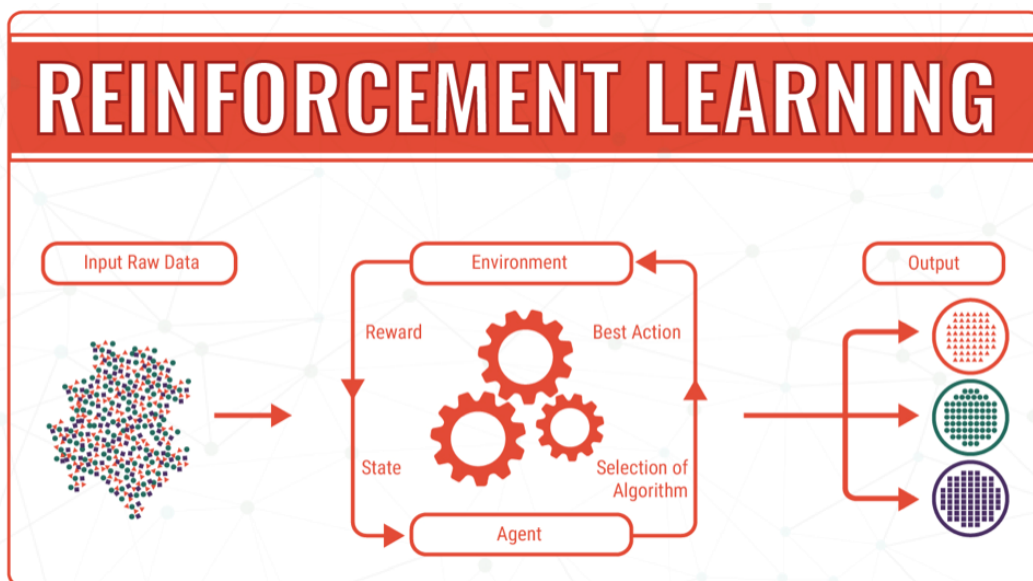
5.1.3 Učení posilováním

Další metodou strojového učení je učení posilováním (ang. *reinforced learning*), které v poslední době zaznamenalo velké úspěchy především díky vítězství umělé inteligence nad světovými šampiony ve hrách typu Go, Shogi a šachy. Princip spočívá v odměňování algoritmu za určité úspěchy případně neúspěchy. Zapotřebí je tedy pro učení zpětná vazba.

Reinforced learning vychází z konceptu učení bez dozoru a poskytuje možnost strojům

určovat, jaké je ideální chování algoritmu v daném kontextu. Na rozdíl od zmíněného typu učení je posilování specifické samostatnou odměňovací funkcí (angl. *reward function*) a cílem algoritmu je prostřednictvím pokusů a omylů postupně zjistit, které akce maximalizují odměny.

Obrázek č. 17: Schéma algoritmu učení posilováním



Zdroj: Machine learning explained [online]. 2018 [cit. 2019-02-23]. Dostupné z: <https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/>

5.1.4 Semi-supervizované učení

Za zmínku stojí i tzv. semi-supervizované učení (angl. *semi-supervised learning*), které kombinuje jak algoritmus s učitelem tak i bez něj. Běžně je uváděn pod Konkrétněji jde o to, že část vstupních dat je se známým výstupem, ale další data, typicky větší, jsou bez něj.

5.2 Předzpracování dat

Je tomu tak běžně, že pro strojové učení je nutné předzpracování dat (angl. *preprocessing*) do jednoduššího vhodného formátu a rozsahu. Standartně se nejdříve tzv. *extrahují features* (angl. *feature extraction*). Často se také stává, že data není možné využít v jejich plném rozsahu (Bishop, 2006, s. 2).

K detekci *features*, tedy zajímavých prvků pro strojové učení, ve výchozích datech jsou naprogramovány tzv. detektory, které data prohledávají a na vstup algoritmu strojového učení dávají právě tyto prvky (Goodfellow, 2016, s. 4-5).

5.3 Generalizace

Protože tréninková data nemohou zahrnovat všechny potenciální vstupy do učícího procesu, algoritmus učení musí být schopen zobecnit (jinak také generalizovat) podstatu již analyzovaných dat (Bishop, 2006, s. 2). A zároveň platí, že příliš jednoduchý odhad modelu nedokáže zachytit důležité aspekty testovacího modelu. Na druhou stranu příliš složité metody mohou modelovat nedůležité detaily, dochází k tzv. *přeučení* (angl. *overfitting*), které je důsledkem přílišné závislosti modelu na trénovacích datech (Bishop, 2006, s. 9). K nadměrnému *přeučení* obvykle dochází, když se používá komplexní metoda ve spojení s příliš malými tréninkovými daty.

Hodnocení výkonu algoritmu lze z pohledu kvality a množství chyb. Chybová funkce (angl. *loss* nebo *cost function*) je například střední kvadratická chyba, která porovnává odhady modelu a testovací výsledky (Bishop, 2006, s. 41). Cílem tréninkové fáze je tuto chybu minimalizovat.

5.4 Backpropagation

Neuronová síť je trénována pomocí výběru vah u všech neuronů a to tak, aby se síť naučila přibližovat k žádaným výsledkům ze známých vstupů. Nicméně pro vícevrstvé sítě je velmi obtížné efektivně analyzovat váhy neuronů.

Nicméně algoritmus zpětného šíření chyb (angl. *backpropagation*) toho schopen je v jednoduché a účinné formě nastavování vah iterativním způsobem (Goodfellow, 2016, s. 204-210; Bishop, 2006, s. 241-245).

Klasická verze učení pomocí *backpropagation* používá optimalizační funkci tak zvaného klesání podle gradientu (angl. *gradient descent*). I přesto, že funkce *gradient descent* může být poměrně časově náročná a není zaručeno, že nalezne globální minimum chyb, je při správné konfiguraci tzv.

hyperparametrů funguje v praxi velmi dobře.

Algoritmus učení zpětným šířením chyb

V první fázi se vstupní vektor hodnot šíří dopředu neuronovou sítí. Před tím byly váhy neuronů inicializovány na náhodné hodnoty.

Proběhne vypočítání sítě a následně je výstup ze sítě porovnán s požadovaným výstupem, který by měl být pro trénovací data znám, za použití funkce ztráty. Následně se vypočítá hodnota této chyby jako gradient funkce ztráty. Při použití střední kvadratické chyby jako funkce ztráty je chybová hodnota výstupní vrstvy jednoduše rozdílem mezi aktuálním a požadovaným výstupem.

Hodnoty chyb se pak šíří zpět sítí, aby se vypočítaly hodnoty chyb skrytých a vstupních neuronů. Nakonec jsou hmotnosti neuronů aktualizovány výpočtem gradientu hmotností a odečtením procentní části gradientu od vah. Tato část se nazývá míra učení a někdy také rychlost učení (Goodfellow, 2016, s. 203-204). Rychlost učení může být pevná nebo dynamická. Poté, co byly váhy aktualizovány, algoritmus pokračuje opětovným prováděním fází s odlišným vstupem a to do té doby, dokud hodnota vah nekonverguje respektive se nezastaví případně proces trénování může být nastaven jen na daný počet opakování neboli tzv. epoch.

6 Minulost, současnost a budoucnost neuronových sítí

Dějiny robustně zpracovává ve své knize Haykin (2002, s. 60–67) a dále také David Kriesl (2012, s. 8–12), který uvádí přehled událostí kategorizovaně a to dle časové linie. Údělem této práce je nicméně pojednání o moderních neuronových sítích, proto jsou dějiny uváděny v kompaktnější, stručnější formě. Na minulost NS pak navazuje kapitola o současném dění s přehledem úspěšných aplikací neuronových sítí, na kterém je zajímavé vidět, jak rozmanitá je přítomnost NS ve fungování společnosti. Práce také pojednává o výhledech do budoucna.

6.1 Počátky a první úspěchy (1943–1960)

- 1943** První z matematický model neuronu. Autoři Warren McCulloch a Walter Pitts realizovali první úspěšné vědeckých bádání neuronových sítí jejíž závěrem bylo vynalezení tzv. **prahové logické jednotky** (angl. *threshold logic unit*) tedy základního typu neuronové jednotky na kterém ukazují, že je schopna realizovat jakoukoliv logickou nebo aritmetickou funkci.
- 1949** Donald Hebb vydává knihu *Organization of Behavior*, ve které bylo navrženo učící pravidlo samostatného neuronu (dnes známé jako **Hebbovské učení**).
- 1951** První **neurpočítač**. Snark byl počítač postavený na bázi umělých neuronových sítí, který uměl nastavit své vlastní váhy. Autor počítače, kognitivní vědec Marvin Minsky, nicméně stroj prakticky nikdy nevyužil.
- 1957/9** Vynález **perceptronu** autorem Frankem Rosenblattem, který zobecňuje McCullochův a Pittsonův model neuronu pro reálná čísla. Perceptron má jeden neuron pro klasifikaci. V roce 1959 Frank Rosenblatt formuluje Teorém o konvergenci perceptronu (angl. *perceptron convergence theorem*).
- 1960** Vytvoření efektivního učícího systému **Adaline** od autorů Bernarda Widrowa a Marciana E. Hoffa.

6.2 Stagnace a pesimismus (1960-1980)

- 1963** **Backpropagation** neboli metoda učení NS pomocí zpětného šíření chyb (Bryson a kol.) je objevena; zůstává však bez větší pozornosti.
- 1969** Kniha **Perceptron** od autorů Martina Minského a Seymoura Paperta důkladně analyzuje možnosti dosavadních perceptronů a zdůrazňuje neschopnost neuronu naučit se realizovat logickou funkci XOR.
- 1973:** První **zima umělé inteligence** (angl. *winter of AI*): dochází ke stagnaci a ukončení financování vývoje umělé inteligence po celém světě (primárně ve Velké Británii, Severní Americe a Sovětském svazu). Vychází také negativní posouzení dosavadního vývoje z reportu „Artificial Intelligence: A General Survey“ realizované Jamesonem Lighthillem v pozdním listopadu toho roku.

V kontextu této situace, kdy se ani nedařilo nalézt dostatečně efektivní metodu trénování MLP (několika vrstevného perceptronu), upadá o NS zájem a to obzvláště od roku 1969.

6.3 Renesance (1980-1992)

- 1982** **Hopfieldovy sítě** jsou objeveny a o neuronové sítě se postupně zvedá zájem
- 1983** Neocognitron, nový neuronový model, je objeven autory Fukushima, Miyaku a Ito, který rozpoznává **ručně psané znaky**.
- 1986** **Backpropagation** je znovu objeven a dodnes je nejvíce užívanou učícím algoritmem neuronových sítí vůbec. Více zpracovává kapitola 5.4.

V souvislosti se zmíněnými pokroky však v éteru zůstávali viset problematické otázky týkající se například tzv. přeučení (ang. *overfitting*, popsáno v kapitole 5. Strojové učení) nebo např. otázky týkající se nalezení optimální struktury NS kupříkladu: „Kdy neuronové sítě přestat trénovat?“ a další.

6.4 Obrat k jiným technologiím (1993-2005)

Vznikají nové technologie, specificky např. SVM (angl. *support vector machine* neboli metody podpůrných vektorů) od autora V. Vapnika (1995), které neuronové sítě znevýhodňují. Dále se také začali více využívat grafické modely.

1998 Yann LeCun vyvinul hluboké konvoluční neuronové sítě, nicméně ty se nedařilo úspěšně trénovat.

6.5 Návrat a velká překvapení (2006 až dodnes)

2006 Vývoj rychlého algoritmu učení (Hinton a kol., 2006) pro tzv. Deep Belief Sítě

2007 Vývoj obecného algoritmu pro **hluboké neuronové sítě** (Yoshua a kol. 2007)

2009 Vývoj sítí založených na hlubokých autoenkódech (angl. *Deep Autoencoders*). Konvoluční neuronové sítě běžící na GPU.

2012 Vítězství **hluboké neuronové sítě AlexNet** v důležité mezinárodní soutěži klasifikace obrázků ImageNet LSVRC (Krizhevsky a kol., 2012; Hinton a kol, 2012)

Vítězství hlubokých NS v mezinárodních soutěžích od té doby jen roste a stejně tak i zájem o NS. Současnost NS dále popisuje kapitola následující.

Závěrem však není zcela od věci konstatovat, že dějiny neuronových sítí se podobají spíše jízdě na horské dráze. Období zájmu a velkého očekávání se snad skoro automaticky střídají s pesimismem a nezájmem (Engelbrech, 2007, s. 13).

Také je vhodné poznamenat důležitý vliv umělé inteligence na NS, který se vývíjel obdobně složitou historií, jak píše například Nilsson (2010).

6.6 Současnost neuronových sítí

Historii překračuje především pokračující výzkum v oblasti umělé inteligence, nicméně fenomenální progres v neuronových sítích zažívá jejich aplikace v soukromé sféře po celém světě. Primárně ve vyspělých státech, kde byl financován vývoj umělé inteligence, a to sice ve Velké Británii⁵, USA, Kanadě, Rusku a Japonsku, nicméně především díky internetu se neuronové sítě aplikují po celém světě a bezprecedentní rozvoj NS a umělé inteligence zažívá Čínská lidová republika. Ve veřejné sféře se NS aplikují také, o tom více tabulka č. 1 níže.

6.6.1 Výzkum

Výzkum probíhá po celém světě a práce se koncentrují na světových konferencích a v mezinárodních vědeckých časopisech, viz přehled hlavních zdrojů níže:

Konference:

- IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP, více na webu konference: www.ieee.org/conferences/tag/sctlspl.html
- Advances Neural Information Processing Systems, NIPS.
Více na webu konference: www.cs.cmu.edu/Groups/NIPS/
- IEEE Workshop on Neural Networks for Signal Processing, NNSP.
Více na webu konference: <http://eivind.imm.dtu.dk/nnsp2000>

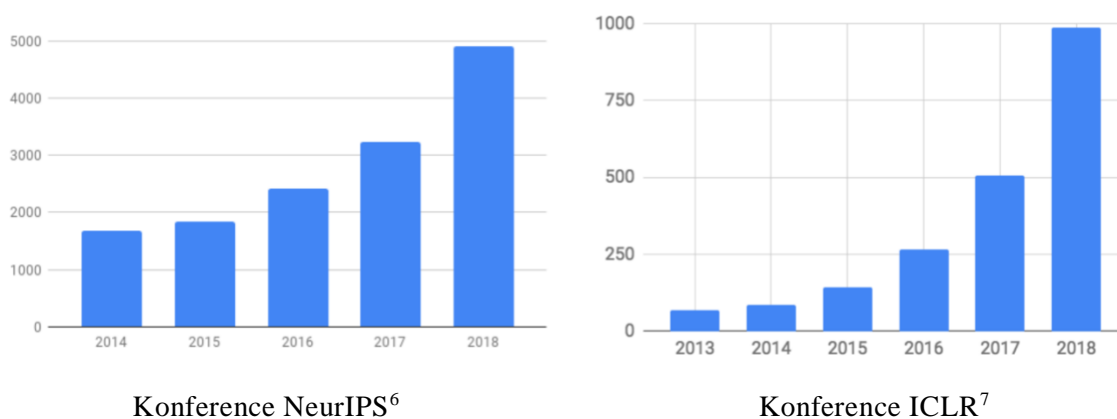
Vědecké časopisy:

- Neural Networks, založen 1988;
- Neural Computation, založen 1989;
- IEEE Transactions on Neural Networks, založen 1990;
- Neural Network World, založen 1991 a další.

Zajímavý je i počet vědeckých prací prezentovaný na renomovaných mezinárodních konferencích pokrývající téma NS. D. Sculley a kol. (2018, s. 2) uvádí tuto statistiku:

⁵ Zkrácený tvar státních úvarů byl použit z důvodu čitelnosti textu.

Obrázek č. 18: Statistika počtu vědeckých článků podaných na konferenci



Zdroj: Sculley a kol. (2018, s. 2)

Statistika z obrázku č. 18 ukazuje absolutní počty podaných článků za posledních několik let ze kterých je vidět jasný trend.

Zároveň od 90. let narůstá počet studijních oborů v oblasti umělé inteligence potažmo NS; renomované univerzity také zakládají nové výzkumné ústavy zaměřující se například neurovýpočty.

I přesto všechno zaznívají kritické ohlasy, a to i od významných výzkumných pracovníků např. François Chollet, zakladatel Kerasu tedy frameworku na učení NS, který v interview (Hackermoon, 2018) mluví o nedostatečném pokroku, respektive jeho přesné vyjádření o výzkumu umělé inteligence pomocí NS je: “research is at plateau”. Nebo také i zakladatel hlubokého učení Geoffrey Hinton v interview (The Medium, 2018) zmiňuje, že pro budoucí vývoj je nutné změnit paradigma učení neuronových sítí a že pro budoucí pokrok je nutné vymyslet nový přístup.

⁶ NeurIPS: Conference on Neural Information Processing Systems

⁷ ICLR: International Conference on Learning Representations

6.6.2 Aplikace neuronových sítí

Jak již bylo zmíněno neuronové sítě se nejen používají, ale také prodávají. Konkrétní úspěšné aplikace jsou vyjmenovány v tabulce č. 2: Přehled úspěšných aplikací neuronových sítí v kapitole 4.3.1.

Mezi současnými trendy umělé inteligence používající neuronové sítě lze aktuálně počítat s aplikacemi v oblasti rozpoznávání obličejů, chatových robotů, zrychlování trénovacího procesu, zrychlování autonomních vozidel a dalších (AiTrends.com, 2019).

Celkově lze říci, že velký posun v aplikaci neurálních sítí v rámci strojového učení začal od roku 2012, kdy neuronová síť, konkrétně konvoluční neuronová síť AlexNet vyhrála soutěže o nejlepší rozpoznání obrazového datasetu ImageNet.

Specifický byl také rok 2018, kdy se navzdory pesimistickému očekávání odborné komunity podařilo porazit světě šampiony v několika komplexních hrách počínaje vítězstvím programu AlphaGo Zero ve 3 hrách zároveň, a to sice ve hře go, šachy a shogi. O co zajímavější je fakt, že se to podařilo díky algoritmu nevyužívající žádné znalosti expertů na hru.

6.6.3 Nedostatky

Jedním z klíčových problémů neuronových sítí dnes je transparentnost procesu realizace algoritmu, tzv. problém **černých skříněk**, který znemožňuje získávat informace o **strategiích** řešení úloh pomocí neuronových sítí (Wooldridge, 2016 a Futureoflife.com, 2018). Dalším problémem je také porozumnění principů budování efektivních neuronových sítí, nicméně na pbou zmíněných problémech se pracuje; konkrétně se jim věnuje anglická firma DeepMind Technologies.

Neuronové sítě také často chybují obzvláště v rozeznávání objektů (Rosenfield a kol, 2018), kteří uvadějí zajímavé příklady typu problému rozeznání z obrázku, zda je detekovaný deštník směrem nahoru nebo dolů.

S rokem 2018 a následně i 2019 se objevuje rozsáhlejší **kritika deep learning algoritmů** a úvahy o jejich limitech (The Medium, 2018; Hackingmachines.com, 2018; Hackermoon.com, 2019) zmiňující jednak jejich náročnost na data a energii s tím, že v některých úlohách mají jednoduše horší výsledky než běžné definitivní vyhledávací algoritmy a to například v úlohách typu obchodního cestujícího, kde je tíženým kritériem škálovatelnost a ekonomická výhodnost. Vše v kontextu toho, že dat bude v následujících letech potřeba ještě více. Jsou zmíněny také **nedostatky učení formou s učitelem** (angl. *supervised learning*).

Vhodné je zde zmínit, že sama umělá inteligence má mnoho nedostatků nebo spíše lépe řečeno problematických otázek, na které neuronové sítě ani často nemohou odpovědět. Faktem ale zůstává, že na nich závisí, protože pokud se je nepodaří vyřešit, nebude se dařit ani neuronové sítě. Níže proto zmiňuje jen pár důležitých a aktuálních problémů umělé inteligence.

Vývoj **obecné umělé inteligence** (angl. *general AI*) potažmo umělé superinteligence je zatím cíl nedosažitelný (The Medium, 2018).

Bezpečnost a odpovědnost robotů je velmi komplikovaná ne-li nereálná (Boddington, 2016). Další komplikace UI jsou zpracovány v pracích V. Müllera (2016, 2019).

6.7 Budoucnost neuronových sítí

Zajímavou predikci vývoje a aplikace neuronových sítí potažmo umělé inteligence zpracovává profesor robotiky na MIT, Rodney Brooks (2019). Predikci systematicky zpracovává a aktualizuje od roku 2018 a prozatím mu vychází spíše pesimistický pohled na vývoj a aplikaci umělé inteligence. Například jednou z predikcí na rok 2020 jsou zprávy (“popular press”) o **konci Deep Learning éry** a rokem 2021 je vyznačena nutnost přechodu k jiným aktuálně neznámým přístupům ke strojovému učení, a to obzvláště pro rozpoznávání hlasu (angl. speech recognition). S čímž souhlasí i zmiňovaný otec zakladatel deep learningu Geoffrey Hinton (The Medium, 2018).

Predikce profesora Brookse jsou poměrně konkrétní a jsou rozpracovány i pro různé aplikace umělé inteligence (např. autonomní automobily a meziplanetární dopravu). Tyto predikce jsou součástí přílohy mé práce.

V lednu 2019 byla provedena rozsáhlá a dosud nevídaná analýza 16 625 vědeckých článků o umělé inteligenci za posledních 25 let (MIT Technology Review, 2019), která naznačuje, že éra **hlubokého učení (angl. deep learning) je u konce**.

Nicméně na otázku budoucího vývoje umělé inteligence, to jest tedy i otázky, zda se neuronové sítě budou i nadále využívat, autor studie profesor Pedro Domingo z Waschingtonské univerzity říká: „*Je nutné si uvědomit, že každé desetiletí (od 50. let 20. století) bylo ovládáno jinou technikou: neuronové sítě na konci 50. a 60. let, v 70. letech dominoval symbolický přístup ke strojovému učení, v 80. letech naopak znalostní systémy, v letech 90. to byly bayesovské sítě, v nultých letech to byly SVM (česky metody podpůrných vektorů) a teď jsou aktuální neuronové sítě.*“ Profesor Domingo na závěr podtrhuje, že na otázku budoucího vývoje umělé inteligence nikdo nezná odpověď.

Část II.
Praktická část

7 Cíle a metody praktické části

Cílem této části práce je vytvořit webovou aplikaci, využívající deep learning algoritmy k detekci objektů na zkušebních obrazových datech.

Záměrem je tak demonstrovat technologické principy programování neuronových sítí a jejich využití.

Aplikace spolu s technologickou dokumentací (Wiki) je dostupná online na adrese <http://90.177.180.207> na portu 80. Dokumentace je dostupná na portu 9000.

7.1 Seznam použitých technologií

Webová aplikace vyžaduje vlastní server. Využit byl server domácí s následujícími technologiemi:

- Server: OS Debian, Apache HTTP Server (virtuální)
- Aplikace: Tensorflow.js a Node.js
- Front-end framework web: Foundation
- Databáze – MySQL

Kód aplikace je uložen v Git repozitáři na serveru GitHub a technologická dokumentace byla sepsána nástrojem Confluence od společnosti Atlassian.

Klíčovou technologií pro tvorbu aplikace je framework Tensflow.js od společnosti Google (někdy také jen TF.js). Důvodem výběru této technologie bylo hned několik:

1. Je postaven na programovacím jazyce JavaScript, který je nativně podporován všemi webovými prohlížeči; jinými slovy Tenserflow.js je stavěný pro webové aplikace.
2. Rychlost trénování u malých modelů NS je stejná u TF.js jako pro práci v jiném frameworku, ať už je to PyTorch, Keras, Matlab, CNTK, MXNet nebo Chainer. Pochopitelně pro větší modely je Tenserflow deset až patnáct krát pomalejší než např. PyTorch.
3. Tenserflow.js je open-source a to například Matlab není.
4. Vzorové modely hlubokých neuronových sítí, typu AlexNet, ResNet, GoogleNet a

další, jsou pro Tensorflow.js dostupné a to bez komplikovaného převodu kódu

5. Dostupná a velmi kvalitní dokumentace celého frameworku

8 Vlastní řešení

Po načtení stránky dostupné na adrese <http://90.177.180.207> se uživatel dostane na uvítací stránku původního webu k této diplomové práci, viz obrázek č. 19 a č. 20.

Viditelné kromě základní charakteristiky práce je seznam s odkazy na využitě technologie. Dále vidět standardizace webu podle HTML5, CSS3 a Blind Friendly Web. Rychlost webu dle Google Page Speed Insights vykazuje 69 bodů ze 100 a UX (User experience, uživatelská zkušenost) je hodnocena 97 body ze 100. Také je možné navštívit dokumentaci k webové aplikaci nebo GIT repozitář.

Obrázek č. 19: Úvodní stránka, 1. část

Diplomová práce
Moderní neuronové sítě

Dan Šilhavý | ČZU v Praze | Katedra informačního inženýrství | 2019

ÚVOD

Tyto webové stránky demonstrují praktickou část mé diplomové práce zabývající se neuronovými učicími systémy. Aplikace jsou zpracovány v jednotlivých funkčních modulech s tím, že stránky i zmíněné moduly jsou dostupné z mobilních zařízení.

Obrat v pozornosti a zájem o umělou inteligenci započíná po konci první dekády 20. století mimo jiné i rozvoj datových setů a programů rozeznávající vizuální objekty. V prvním modulu je proto zpracován program klasifikující objekty ze slavného datového souboru Kalifornské univerzity v Irvine [Iris dataset](#).

Účelem této prezentace je poukázat na **aplikace moderních metod učení neuronálních sítí** a proto je zde v závěru uveden i jejich souhrn.

Technologie webu: [Foundation](#) \ [TensorFlow.js](#) \ [Node.js](#)

Standardizace webu dle: [HTML5](#) \ [CSS3](#) \ [Blind Friendly Web 2.3](#) \ [Google Page Insights](#)

Dokumentace a Wiki \ [Git repozitář](#)

INFORMACE O DIPLOMOVÉ PRÁCI

TÉMA	AUTOR	VEDOUČÍ PRÁCE
Moderní metody učení neuronových sítí	Dan Šilhavý	doc. Ing. Arnošt Veselý, CSc.

Zdroj: <http://90.177.180.207:80> [cit. 2019-03-21].

Na druhé části úvodní stránky, viz obrázek č. 20, jsou viditelné jednotlivé funkční moduly naprogramované aplikace spolu s odkazy na obdobné aplikace s popisem toho,

který konkrétní model neuronových sítí využívají a zároveň také do jakých kategorií modely spadají.

V závěru je možné stáhnout diplomovou práci nebo navštívit web frameworku Foundation a mimo jiné také navštívit stránku s informacemi o přístupnosti tohoto průvodního webu (viz Obrázek č. 12). Na webu je uveden rok jeho výroby a licence, pod kterou funguje.

Obrázek č. 20: Úvodní stránka, 2. část

The screenshot displays a dark-themed website with an orange header. It is organized into three main sections:

- FUNKČNÍ MODULY APLIKACE**: A 2x2 grid of red buttons listing:
 1. Detekce objektů z obrázků, klasifikační úloha
 2. Iris, klasifikační úloha
 3. Detekce objektů v reálném* čase, klasifikační úloha
 4. Lineární regrese
- ANALOGICKÉ APLIKACE MODERNÍCH METOD NEURONOVÝCH SÍTÍ**: A 4x2 grid of blue buttons listing:
 - KNN Classifier (PoseNet:CNN)
 - Text Generation (Ernest Hemingway Model:LSTM)
 - Object Detection (YOLO:CNN)
 - Music Generation (RNN)
 - Skin Classification (MobileNet:CNN)
 - Number Recognition (MNIST model:CNN)
 - Human Pose Estimation (PoseNet: CNN)
 - Další příklady aplikací (ML)
- DIPLOMOVÁ PRÁCE**: A section with the text "Zde si můžete stáhnout moji práci v pdf." and a blue button labeled "Stáhnout práci" with a download icon.

At the bottom, there is a small dog icon, the text "Prohlášení o přístupnosti webu", and the copyright notice "Dan Šihavy © 2019".

Zdroj: <http://90.177.180.207:80> [cit. 2019-03-21].

Obrázek č. 21: Stránka s prohlášením o přístupnosti webu

Prohlášení o přístupnosti webu

Vzhled stránky

Tato webová prezentace byla vytvořena podle metodiky *Blind Friendly Web 2.3*. a splňuje i pravidla s nejnižší prioritou. Stránky je možné používat i při vypnutí grafických prvků.

Barevné kombinace

Barevné kombinace splňují pravidlo č. 9 s nejvyšší prioritou o kontrastu barev. Tato skutečnost byla ověřena pomocí on-line nástroje dostupného na webu *sova v síti*.

Odkazy

Veškeré odkazy směřující mimo tyto webové stránky jsou označeny textem "externí odkaz" v titulku a otevírají se v novém okně.

1. Každý netextový prvek nesoucí významové sdělení musí mít svou textovou alternativu.
2. Multimediální prvky nesoucí významové sdělení musí být doplněny textovými titulky, pokud nejsou jen alternativou k existujícímu textovému obsahu.
3. Informace sdělované vizuální podobou webových stránek, tvary jednotlivých prvků, jejich velikostí, pořadím nebo umístěním musí být dostupné i v případě, že uživatel nemůže tyto aspekty vnímat.
4. Informace sdělované barvou musí být dostupné i bez barevného rozlišení.
6. Barvy popředí a pozadí textu (nebo textu v obrázcích) musí být vůči sobě dostatečně kontrastní, pokud text nese významové sdělení.
6. Velikost písma musí být možné zvětšit alespoň na 200 % a zmenšit alespoň na 50 % původní hodnoty pomocí standardních funkcí prohlížeče. Při změně velikosti nesmí docházet ke ztrátě obsahu nebo funkcionality.
7. Obsah ani kód webové stránky nesmí předpokládat ani vyžadovat konkrétní výstupní či ovládací zařízení.
8. Načtení nové webové stránky či přesměrování je možné jen po aktivaci odkazu nebo po odeslání formuláře
9. Načtení nové webové stránky do nového okna prohlížeče musí být možné jen v odůvodněných případech a uživatel na to musí být předem upozorněn.
10. Na webové stránce nesmí docházet rychleji než třikrát za sekundu k výrazným změnám barevnosti, jasů, velikostí nebo umístění prvku.
11. Zvuk, který zní na webové stránce déle než tři sekundy, musí být možné na této webové stránce vypnout nebo upravit jeho hlasitost.
12. Rozsáhlé obsahové bloky musí být rozděleny do menších výstižně nadepsaných celků.
13. Navigace musí být srozumitelná a konzistentní a na všech webových stránkách orgánu veřejné správy obdobná. Od ostatního obsahu webové stránky musí být zřetelně oddělena.
14. Každá webová stránka (kromě úvodní webové stránky) musí obsahovat odkaz na vyšší úroveň v hierarchii webových stránek a odkaz na úvodní webovou stránku.
15. Každá webová stránka musí mít výstižný název odpovídající jejímu obsahu.
16. Každý formulářový prvek musí mít popisek vystihující požadovaný obsah.
17. Text odkazu nebo jeho přímo související text musí výstižně popisovat cíl odkazu. Jestliže odkaz vede na jiný typ souboru, než je webová stránka, musí být odkaz doplněn sdělením o typu a případně velikosti tohoto souboru.
18. Každý rám musí mít vhodné jméno či popis vyjadřující jeho smysl a funkčnost.
19. Sémantické značky, které jsou použity pro formátování obsahu, musí být použity ve zdrojovém kódu tak, aby odpovídaly významu obsahu.
20. Prvky značkovacího jazyka, které jsou párové, musí mít vždy uvedenu počáteční a koncovou značku. Značky musí být správně zanořeny a nesmí docházet k jejich křížení.
21. Ve zdrojovém kódu musí být určen hlavní jazyk obsahu webové stránky.
22. Prvky tvořící nadpisy a seznamy musí být korektně vyznačeny ve zdrojovém kódu a musí být výstižné.
23. Je-li tabulka použita pro zobrazení tabulkových dat, musí obsahovat značky pro záhlaví řádků nebo sloupců.
24. Obsah všech tabulek musí dávat smysl čtený po řádcích zleva doprava.
25. Každá webová stránka musí vždy obsahovat prohlášení o tom, že forma uveřejnění informací je v souladu s touto vyhláškou (prohlášení o přístupnosti) nebo odkaz na toto prohlášení.

Dan Šilhavý | © 2019 | Zpět na hlavní stranu

Zdroj: <http://90.177.180.207/prohlaseni> [cit. 2019-03-21].

Na stránce s prohlášením o přístupnosti je vidět seznam pravidel, které jsou ze značné míry webem splněny.

8.1 Funkční moduly

Funkčním modulem je chápána samostatně fungující část celé webové aplikace, splňující dílčí cíl praktické části této diplomové práce.

Modul 1 – Detekce objektů z obrazu

Stránka s modulem č. 1 nejdříve aplikaci a využitý neuronový model popisuje; uvádí také schéma algoritmu, viz obrázek č. 22.

Obrázek č. 22: Funkční modul 1 – Detekce z obrazů, informační část

Detekce objektů v obrazech

Tento modul využívá hlubokou neuronovou síť MobileNet 1/224 s architekturou 2 rozdílných konvolucí ve směru hloubky (depthwise separable convolutions), které napomáhají zmenšení výpočetní náročnosti aplikace.

Trénování probíhalo s učitelem (supervised learning) formou zpětného šíření chyby (backpropagation). Jedná se o poměrně menší konvoluční síť, jejíž schéma je uvedeno níže.

```
graph BT; subgraph Path1; C1[konvoluce 3x3] --> BN1[batch normalizace]; BN1 --> R1[ReLU]; end; subgraph Path2; C2[konvoluce dw 3x3] --> BN2[batch normalizace]; BN2 --> R2[ReLU]; C3[konvoluce 1x1] --> BN3[batch normalizace]; BN3 --> R3[ReLU]; end; R1 --> R4[ReLU]; R3 --> R4; R4 --> BN4[batch normalizace]; BN4 --> R5[ReLU];
```

Zdroj: <https://arxiv.org/abs/1704.04861>

Více o MobileNet sítích pojednává diplomová práce.

Pozn. Odhady jsou přesné především pro objekty ku příkladu tužky, papíry, šálky kávy, klávesnice, lahve a obdobně. Horší výsledky má detekce lidí.

Zdroj: <http://90.177.180.207/moduly/mobileNet/> [cit. 2019-03-21].

Dále je na stránce již část aplikační, viz obrázek č. 23. Základní funkcí je možnost nahrát jakýkoliv obrázek do velikost 5 MB, který je následně analyzován a v pravé části webu se vypisují kategorie objektů spolu s jejich pravděpodobností. Na obrázku č. 23 je například vidět, že program z 32 % odhaduje, že na obrázku se vyskytuje norfolkský teriér a z 8% norwichský teriér.


Obrázek č. 23: Funkční modul 1 – Detekce z obrazů, aplikační část

Více o MobileNet sítích pojednává diplomová práce.


Pozn. Odhady jsou přesné především pro objekty ku příkladu tužky, papíry, šálky kávy, klávesnice, lahve a obdobně. Horší výsledky má detekce lidí.

Prosím, nahrajte obrázek k detekci:

Rozpoznáno za 62ms.



Norfolk terrier	0.321
Norwich terrier	0.078
Lhasa, Lhasa apso	0.077
komondor	0.064
Dandie Dinmont, Dandie Dinmont terrier	0.062
soft-coated wheaten terrier	0.050
Lakeland terrier	0.033
toy poodle	0.030
Border terrier	0.030
Maltese dog, Maltese terrier, Maltese	0.029

 [Prohlášení o přístupnosti webu](#) [Zpátky na úvod](#)

Zdroj: <http://90.177.180.207/modules/mobileNet/> [cit. 2019-03-21].

Pokud je uživatel přihlášen, může sdílet obsah přímo z tohoto webu prostřednictvím tlačítka Post (viz Obrázek č. 15)

Modul 2 – Klasifikace kosatců z Iris datového setu

Tento modul umožňuje klasifikovat různé odrůdy kosatců (lat. *iris*), pomocí jednoduché dopředného modelu NS se 4 vrstvami. Vedlejší funkcí je možnost nahrát vlastní model NS a porovnat ho s již natrénovaným modelem, který je výchozím modelem odhadu typu kosatců. Stránka k tomuto poskytuje základní analýzu přesnosti modelu a také matici záměn (angl. *confusion matrix*), viz obrázek č. 26.

V úvodu stránka podává informace o modelu, viz obrázek č. 24 a po ní následuje je aplikační část, viz obrázek č. 25.

Obrázek č. 24: Funkční modul 2 – Klasifikace kosatců, informační část

Klasifikace kosatců

Úlohou je zde pro neuronovou síť správné rozpoznání ze 3 kategorií květiny Iris. Vstupní data jsou numerická a pocházejí ze slavného souboru **Kalifornské univerzity v Irvine - Iris dataset**.

Soubor má 150 záznamů, každý záznam má po 5 hodnotách. Kritérii pro rozlišení jednotlivých typů kosatců jsou: délka a šířka jejich okvětního lístku a délka a šířka květů.

Testován a navrhnut byl sekvenční model s 2 hustými vrstvami, 3 neurony na výstupu a 10 na vstupu. Aktivační funkce byla pro vstupní neurony zvolena softmax a pro vstupní vrstvu sigmoid. Optimalizační funkcí byl ozkoušen algoritmus Adam, který bývá považován za celkově výhodnější algoritmus než Gradient Descent - více v publikaci zde.. Chybová funkce byla zvolena Cross Entropy, které vychází lépe než RMSE a které se lépe hodí pro klasifikační úlohy.

MANUÁL

- Pomocí tlačítek níže můžete buď trénovat nový model od nuly nebo načíst již natrénovaný model a testovat jeho kvalitu.
- Pokud trénujete model od nuly, můžete jej také uložit do lokálního úložiště prohlížeče.
- Pokud nahrajete již trénovaný model, můžete upravit jeho vlastnosti v prvním řádku [Testových příkladů](#).

TRÉNOVAT MODEL

Epochy:

Učící stupeň:

Zdroj: <http://90.177.180.207/moduly/mobileNet> [cit. 2019-03-21].

Obrázek č. 25: Funkční modul 2 – Klasifikace kosatců, aplikační část

TRÉNOVAT MODEL

Epochy:

Užící stupeň:

Trénovat model od začátku

ULOŽIT/NAHRÁT MODEL

Nahrát již učený model

Nahrát lokální model Uložit model Odebrat model

STATUS QUO TRÉNOVÁNÍ

>Čeká na trénování.

GRAFY TRÉNOVACÍHO PROCESU

Ztráta:

Přesnost:

TESTOVÉ PŘÍKLADY

Délka okvětního lístku	Šířka okvětního lístku	Délka květu	Šířka květu	Pravda	Predikce	Pravděpodobnost
<input type="text" value="5.1"/>	<input type="text" value="3.5"/>	<input type="text" value="1.4"/>	<input type="text" value="0.2"/>			




Zdroj: <http://90.177.180.207/moduly/mobileNet> [cit. 2019-03-21].


Obrázek č. 26: Funkční modul 2 – Klasifikace kosatců, část analytická

GRAFY TRÉNOVACÍHO PROCESU


Ztráta:



Přesnost:



Confusion Matrix:



TESTOVÉ PŘÍKLADY

Délka okvětního lístku	Šířka okvětního lístku	Délka květu	Šířka květu	Pravda	Predikce	Pravděpodobnost
5.1	3.5	1.4	0.2		Iris-setosa	0.970 0.029 0.000
5.2	3.4	1.4	0.2	Iris-setosa	Iris-setosa	0.968 0.032 0.000
5.0	3.0	1.6	0.2	Iris-setosa	Iris-setosa	0.944 0.053 0.001
4.4	2.9	1.4	0.2	Iris-setosa	Iris-setosa	0.950 0.049 0.001
4.5	2.3	1.3	0.3	Iris-setosa	Iris-setosa	0.903 0.095 0.002
5.0	3.4	1.6	0.4	Iris-setosa	Iris-setosa	0.951 0.048 0.001

Zdroj: <http://90.177.180.207/moduly/mobileNet> [cit. 2019-03-21]

Modul 3 – Detekce objektů v reálném čase

Tento modul umožňuje detekovat objekty přímo z kamery zařízení uživatele skrze takzvaný model NS YOLO, viz obrázek č. 24.

Obrázek č. 27: Funkční modul 3 – Detekce z kamery, aplikační část

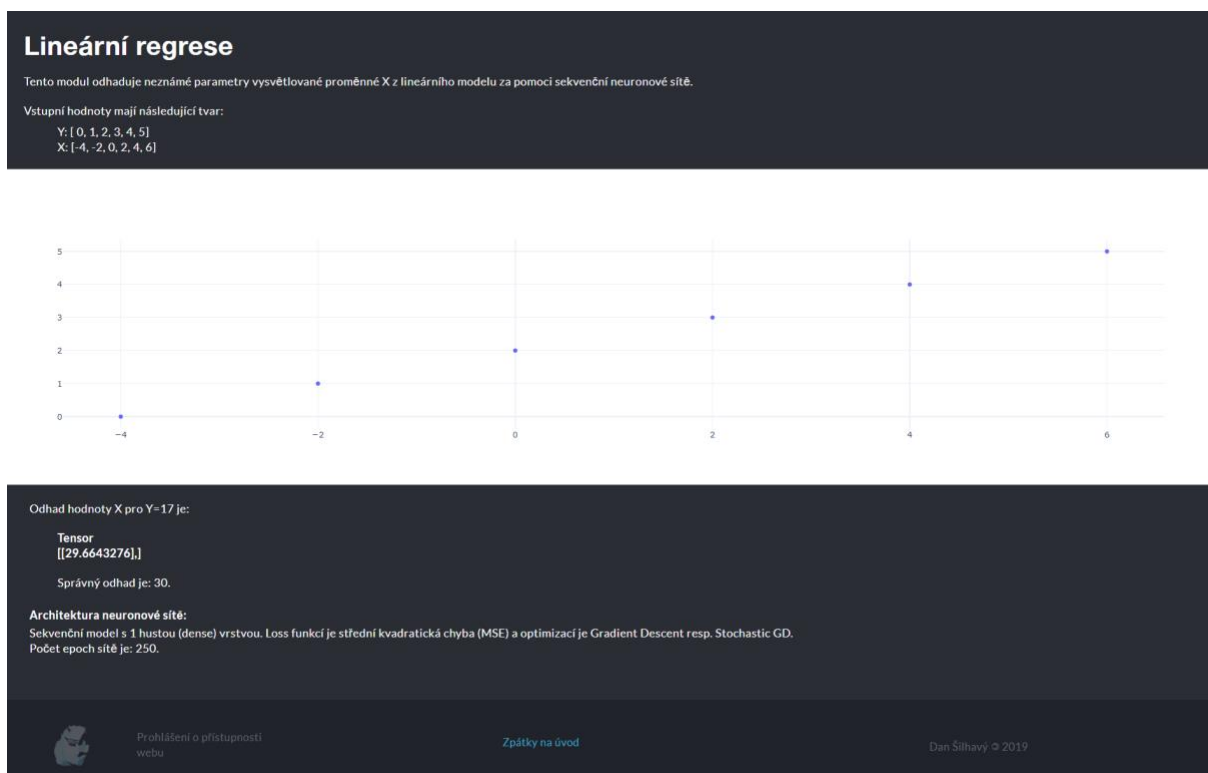


Zdroj: <http://90.177.180.207/moduly/mobileNet> [cit. 2019-03-21].

Modul 4 – Jednoduchá lineární regrese

Závěrečný modul řeší jednoduchou úlohu lineární regrese pomocí jedné z nejjednodušších hlubokých neuronových sítí, viz obrázek č. 29.

Obrázek č. 28: Funkční modul 4 – Lineární regrese



Zdroj: <http://90.177.180.207/moduly/mobileNet> [cit. 2019-03-21].

Stránka nejdříve podává informaci o řešené úloze a následně ji sama počítá. Uživatel si pak může sám ověřit, jak totálně neefektivní je řešení takovýchto úloh pomocí hlubokých neuronových sítí.

9 Resumé a závěry z práce

Hlavním cílem praktické části této práce bylo ozkoušení hlubokých modelů neuronových sítí. To bylo realizováno 4 modely, a to od složitých pod nejjednodušší.

Zjištěny byly tři hlavní závěry:

a) Pro jednoduché úlohy typu lineární regrese se hluboké neuronové sítě nehodí jednak nepřesností odhadu a jednak časovou náročností.

b) Naopak pro složité úlohy typu detekce objektů z obrazu jsou hluboké neuronové sítě velmi efektivní; nicméně rychlost detekce závisí také na využití technologii. Tensorflow.js je v tomto ohledu ne zcela adekvátní, spíše vhodný pro prototypování, protože je jednodušší s ním pracovat.

c) Nejefektivnějším hlubokým učícím modelem je jednoznačně model první, čili MobileNet verze 1.0. Nicméně detekce osob nebo zvířat, která jsou v pozadí obrázku je velmi slabá pod 15% hladinou detekovatelnosti; což je nicméně zřejmě záměrem tohoto modelu, který je de facto modelem komprimovaným a byl navrhnut pro mobilní zařízení, takže se snaží optimalizovat dobu detekce v závislosti na dostatečné úspěšnost rozpoznání objektů z kamery mobilních telefonů

Nejnáročnější část realizace aplikace byla paradoxně ve výběru frameworku. Prvním vyzkoušeným bylo prostředí Matlab, nicméně to pro tvorbu webové aplikace není zaměřeno.

K širšímu studiu by určitě byla zajímavá analýza optimalizace hlubokých modelů neuronových sítí v závislosti na zadané úlohy.

Část III.

Diskuze a závěrečné zhodnocení

10 Závěr

Předkládaná diplomová práce uceleně zpracovává téma neuronových sítí v rámci strojového učení se zaměřením na řešení úloh rozpoznávání objektů z obrazů. Za nejdůležitější přínosy lze považovat:

1. Přehled nových poznatků o teorii a praxi rychle se rozvíjející oblasti neuronových sítí, a to specificky za poslední desetiletí. Práce čerpá z velkého množství zdrojů, které se ne vždy tematicky doplňují a uceleně je řadí do jednoho rámce – neuronové sítě. Ukazuje například na to, že neuronové sítě mohou být dobrým prediktorem vývoje umělé inteligence.
2. Nepodceňoval bych ani dostupnost práce v českém jazyce; protože příliv nových odborných termínů je pro oblast umělé inteligence daný a mnohé z nich již dnes nemají českou variantu. Práce se proto snažila uvádět termíny v obou mutacích – v české i v anglické, a to nejen pro seznam pojmů a zkratek. Do budoucna tak může sloužit dalším badatelům a studentům při hledání kompaktnějšího zdroje překladů.
3. Podrobným porovnáním složitosti několika vzorových modelů neuronových sítí, tím je možno tvrdit, že diplomové práci se podařilo splnit její zadání.

Význam v pokračování a rozšiřování této práce vidím ve dvou rovinách:

1. Je tu potenciál pokračovat v kapitolách moderního hlubokého učení a neuronových sítí. Konkrétně by budoucím výzkumníkům mohl být nápomocný i například rejstřík pojmů s překladem odborných termínů, a to specificky analýz architektury nových neuronových sítí.
2. Za druhé je tu fakt, že výzkum umělé inteligence potažmo neuronových sítí má široké uplatnění v oblasti propojování vědecké a korporátní sféry. Běžně dnes univerzity například soutěží v mezinárodních kláních o nejlepší řešení úkolů neuronovými modely, které byly zadány obchodní, privátní sférou. Stejnak tomu je s i novými univerzitními výukovými kurzy, které jsou zaměřené na umělou inteligenci a ve kterých značnou část kurzu tvoří odborníci z obchodních lů.společností. Svět umělé inteligence je v tomto ohledu mnohem více propojen a výzkum v něm hraje pozitivní roli.li

11 Použité zdroje

- AI in Agriculture – Present Applications and Impact*. Emerj.cotzuutzm [online]. Emerj Artificial Intelligence Research © 2019. 2019-02-15 [cit. 2019-03-20]. Dostupné z: www.emerj.com/ai-sector-overviews/ai-agriculture-present-applications-impact/
- ALPAYDIN, Ethem, 2010. *Introduction to Machine Learning*. Massachusetts: The MIT Press. p. 9. ISBN 978-0-262-01243-0.
- BISHOP, Christopher. M., 2006. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. USA, New York: Springer. ISBN: 978-0387310732
- BODDINGTON, Paula, 2016. *EPSRC Principles of Robotics: Commentary on safety, robots as products, and responsibility*. Ethical Principles of Robotics, special issue, s. 170-176. DOI: 10.1080/09540091.2016.1271396
- CARVER, Mead, 1990. *Neuromorphic electronic systems*. Proceedings of the IEEE, vol. 78 n. 10. s. 1629–1636. DOI:10.1109/5.58356
- Comparison between conventional computers and neural networks*. Stanford Computer Science [online]. 2019 © Stanford University [cit. 2019-03-20]. Dostupné z: <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/Comparison/comparison.html>
- ENGELBRECHT, Andries P., 2007. *Computational Intelligence: an introduction*. 2nd ed. Chichester, England: Hoboken, N.J.: John Willey. ISBN: 978-0470035610.
- GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. 2016. *Deep learning*. Cambridge, Massachusetts: The MIT Press. ISBN 978-0262035613.
- GUO, Chuan a kol., 2017. *On Calibration of Modern Neural Networks*. ICML. Dostupné z: <https://arxiv.org/abs/1706.04599>
- HAGAN, Martin T. et al., 2016. *Neural network design*. 2nd ed. S. 1.: s. n. ISBN: 978-0971732117.
- HAYKIN, Simon, 2002. *Neural networks: a comprehensive foundation*. 2nd ed. Upper Saddle River, N.J.: Prentice Hall. ISBN: 978-0132733502
- Here Are Five Top AI Trends for 2019*. AITRENDS.com [online]. Cambridge Innovation Institute © 2019. 2019-01-19 [cit. 2019-03-21]. Dostupné z: www.aitrends.com/neural-networks/here-are-five-top-ai-trends-for-2019/

- HINTON, Geoffrey E. et col. 2012. *ImageNet Classification with Deep Convolutional Neural Networks*. Neural Information Processing Systems. DOI: 25. 10.1145/3065386.
- HINTON, Geoffrey, Simon OSINDERO, Yee-Whye TEH, 2006. *A fast learning algorithm for deep belief nets*. In *Neural Comput.* Vol. 18, No. 7, s. 1527-1554. DOI: 10.1162/neco.2006.18.7.1527
- In defense of skepticism about deep learning*. 2018. The Medium [online]. The Medium Corporation © 2012–2019. 2018-01-14 [cit. 2019-03-21]. Dostupné na: www.medium.com/@GaryMarcus/in-defense-of-skepticism-about-deep-learning-6e8bfd5ae0f1
- Interview with The Creator of Keras, AI Researcher: François Chollet*. Hackernoon.com [online] The Medium Corporation © 2012–2019. 2018-11-15 [cit. 2019-03-21]. Dostupné na: <https://hackernoon.com/interview-with-the-creator-of-keras-ai-researcher-françois-chollet-823cf1099b7c>
- Interview of Geoffrey Hinton*. The Medium [online]. The Medium Corporation © 2012–2019. 2018-05-27 [cit. 2019-03-21]. Dostupné na: <https://medium.com/@imior/interview-of-geoffrey-hinton-80c48a939282>
- Is another AI winter coming?* Hackernoon.com [online] The Medium Corporation © 2012–2019. 2018-11-15 [cit. 2019-03-21]. Dostupné na: <https://hackernoon.com/is-another-ai-winter-coming-ac552669e58c>
- KRIESEL, David, 2007. *A Brief Introduction to Neural Networks*. Bonn: Rheinische Friedrich Wilhelms Universität. [cit. 2019-01-23]. Dostupné z: www.dkriesel.com/en/science/neural_networks
- KOHONEN, Tuevo, 2013. *Essentials of the self-organizing map*. *Neural Networks Journal*. Vol. 37, No. 1, s. 52-65. DOI: 10.1016/j.neunet.2012.09.018
- LECUN, Yann, Yoshua BENGIO a Geoffrey HINTON. 2015. *Deep Learning*. *Nature*. 521. 436-44. DOI 10.1038/nature14539.
- LONG, Lyle N., Ankur GUPTA, 2008. *Scalable massively parallel artificial neural networks*. *Journal of Aerospace Computing, Information and Communication*. Vol. 5, No. 1, s. 3-15. DOI: 10.2414/1.31026

- Machine learning explained. Big Data Made Simple* [online] Crayon Data © 2019. 2018-02-15 [cit. 2019-02-19]. Dostupné z: <https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/>
- MÜLLER, Vincent, 2016. *Fundamental Issues of Artificial Intelligence*. DOI: 10.1007/978-3-319-26485-1
- MÜLLER, Vincent, 2019. *Ethics of AI and robotics*. Stanford Encyclopedia of Philosophy Palo Alto: CSLI, Stanford University – Latest Draft.
- NILSSON, Nils J., 2010. *The quest for artificial intelligence: a history of ideas and achievements*. New York: Cambridge University Press. ISBN 978-052-1122-931.
- ROSENFELD, Amir a kol., 2018. *The Elephant in the Room*. DOI: 10.13140/RG.2.2.15295.20642. <https://arxiv.org/abs/1808.03305>
- RUSSELL, Stuart J., Peter NORVIG a Ernst DAVIS, 2010. *Artificial intelligence: a modern approach*. 3rd ed. Upper Saddle River, NJ, USA : Prentice Hall. ISBN 978-013-6042-594
- ŠILHAVÝ, Dan. *Sociální sítě*. Praha, 2015. Bakalářská práce. Česká zemědělská univerzita v Praze, Provozně ekonomická fakulta Katedra informačních technologií, 2015-05-23.
- The mostly complete chart of Neural Networks, explained*. TowardsDataScience.com [online] The Medium Corporation © 2012 - 2019. 2017-04-04 [cit. 2019-01-19]. Dostupné z: <https://towardsdatascience.com/the-mostly-complete-chart-of-neural-networks-explained-3fb6f2367464>
- The Unreasonable Reputation of Neural Networks*. ThinkingMachines.com [online]. Massachusetts institute of technology © 2019. 2018-01-12 [cit. 2019-02-19]. Dostupné z: <http://thinkingmachines.mit.edu/blog/unreasonable-reputation-neural-networks>
- Towards a Code of Ethics in Artificial Intelligence with Paula Boddington*. Futureoflife.org [online]. 2019 © Future of Life Institute. 2017-06-31 [cit. 2019-03-21]. Dostupné z: www.futureoflife.org/2017/07/31/towards-a-code-of-ethics-in-artificial-intelligence/
- VAPNIK, Vladimir, 1995. *The Nature of Statistical Learning Theory*. New York: Springer Verlag. ISBN: 13: 9780387987804.

- VESELÝ, Arnošt, 2012. *Metody umělé inteligence*. Vyd. 1. Praha : Česká zemědělská univerzita, Provozně ekonomická fakulta. ISBN 978-80-213-2295-0.
- WEHLE, Hans-Dieter, 2017. *Machine Learning, Deep Learning, and AI: What's the Difference?* Konference Data Scientist Innovation Day. [cit. 2019-01-23]. Dostupné na: www.researchgate.net/publication/318900216
- WOOLDRIDGE, Duncan, 2016. *Visibility and realism: Photography and the problems of transparency*. In *Philosophy of Photography*. Vol. 7. No. 1. s 11-20. DOI: 10.1386/pop.7.1-2.11_1
- WRÓBLEWSKI, Piotr, 2015. *Algoritmy*. Přel. J. Goner. Brno : Computer Press. ISBN: 978-80-251-4126-7.
- YOSHUA, Bengio, Pascal LAMBLIN, Dan POPOVICI, Hugo LAROCHELLE, 2007. *Greedy layer-wise training of deep networks*. In *Advances in Neural Information Processing Systems*. 19. MIT Press, Cambridge, MA, USA, 153-160.
- Zitzewitz, Gustav, 2017. *Survey of neural networks in autonomous driving* [cit. 2019-03-23]. Dostupné na: www.researchgate.net/publication/324476862

Pro zpracování tabulky č. 1 Přehled úspěšných aplikací neuronových sítí bylo čerpáno z těchto zdrojů:

- Applications of artificial intelligence in digital marketing*. Adext [online]. Adext Corp © 2018. 2018-05-11 [cit. 2019-03-20]. Dostupné z: www.blog.adext.com/applications-artificial-intelligence-ai-digital-marketing/
- Google Is Using AI to Make a Huge Change to Its Translate Tool*. Observer Media © 2019 [online]. 2017-03-06 [cit. 2019-03-20]. Dostupné z: www.observer.com/2017/03/google-translate-neural-update/
- JOHNSON, Justin a kol. 2016. *Perceptual Losses for Real-Time Style Transfer and Super-Resolution*. In *Conference: European Conference on Computer Vision*. 9906. s. 694-711. DOI: 10.1007/978-3-319-46475-6_43

12 Přílohy

Příloha I. Aktualizované predikce profesora Brookse z jara 2019

Prediction [AI and ML]	Date	2018 Comments	Updates
Academic rumblings about the limits of Deep Learning	BY 2017	Oh, this is already happening... the pace will pick up.	20190101 There were plenty of papers published on limits of Deep Learning. I've provided links to some right below this table.
The technical press starts reporting about limits of Deep Learning, and limits of reinforcement learning of game play.	BY 2018		20190101 Likewise some technical press stories are linked below.
The popular press starts having stories that the era of Deep Learning is over.	BY 2020		
VCs figure out that for an investment to pay off there needs to be something more than "X + Deep Learning".	NET 2021	I am being a little cynical here, and of course there will be no way to know when things change exactly.	
Emergence of the generally agreed upon "next big thing" in AI beyond deep learning.	NET 2023 BY 2027	Whatever this turns out to be, it will be something that someone is already working on, and there are already published papers about it. There will be many claims on this title earlier than 2023, but none of them will pan out.	
The press, and researchers, generally mature beyond the so-	NET 2022	I wish, I really wish.	

Prediction [AI and ML]	Date	2018 Comments	Updates
called "Turing Test" and Asimov's three laws as valid measures of progress in AI and ML.			
Dexterous robot hands generally available.	NET 2030 BY 2040 (I hope!)	Despite some impressive lab demonstrations we have not actually seen any improvement in widely deployed robotic hands or end effectors in the last 40 years.	
A robot that can navigate around just about any US home, with its steps, its clutter, its narrow pathways between furniture, etc.	Lab demo: NET 2026 Expensive product: NET 2030 Affordable product: NET 2035	What is easy for humans is still very, very hard for robots.	
A robot that can provide physical assistance to the elderly over multiple tasks (e.g., getting into and out of bed, washing, using the toilet, etc.) rather than just a point solution.	NET 2028	There may be point solution robots before that. But soon the houses of the elderly will be cluttered with too many robots.	
A robot that can carry out the last 10 yards of delivery, getting from a vehicle into a house and putting the package inside the front door.	Lab demo: NET 2025 Deployed systems: NET 2028		
A conversational agent that both carries long term context, and does not easily fall into recognizable and repeated patterns.	Lab demo: NET 2023 Deployed systems: 2025	Deployment platforms already exist (e.g., Google Home and Amazon Echo) so it will be a fast track from lab demo to wide spread deployment.	

Prediction [AI and ML]	Date	2018 Comments	Updates
An AI system with an ongoing existence (no day is the repeat of another day as it currently is for all AI systems) at the level of a mouse.	NET 2030	I will need a whole new blog post to explain this...	
A robot that seems as intelligent, as attentive, and as faithful, as a dog.	NET 2048	This is so much harder than most people imagine it to be--many think we are already there; I say we are not at all there.	
A robot that has any real idea about its own existence, or the existence of humans in the way that a six year old understands humans.	NIML		

Zdroj: <http://rodneybrooks.com/predictions-scorecard-2019-january-01/>

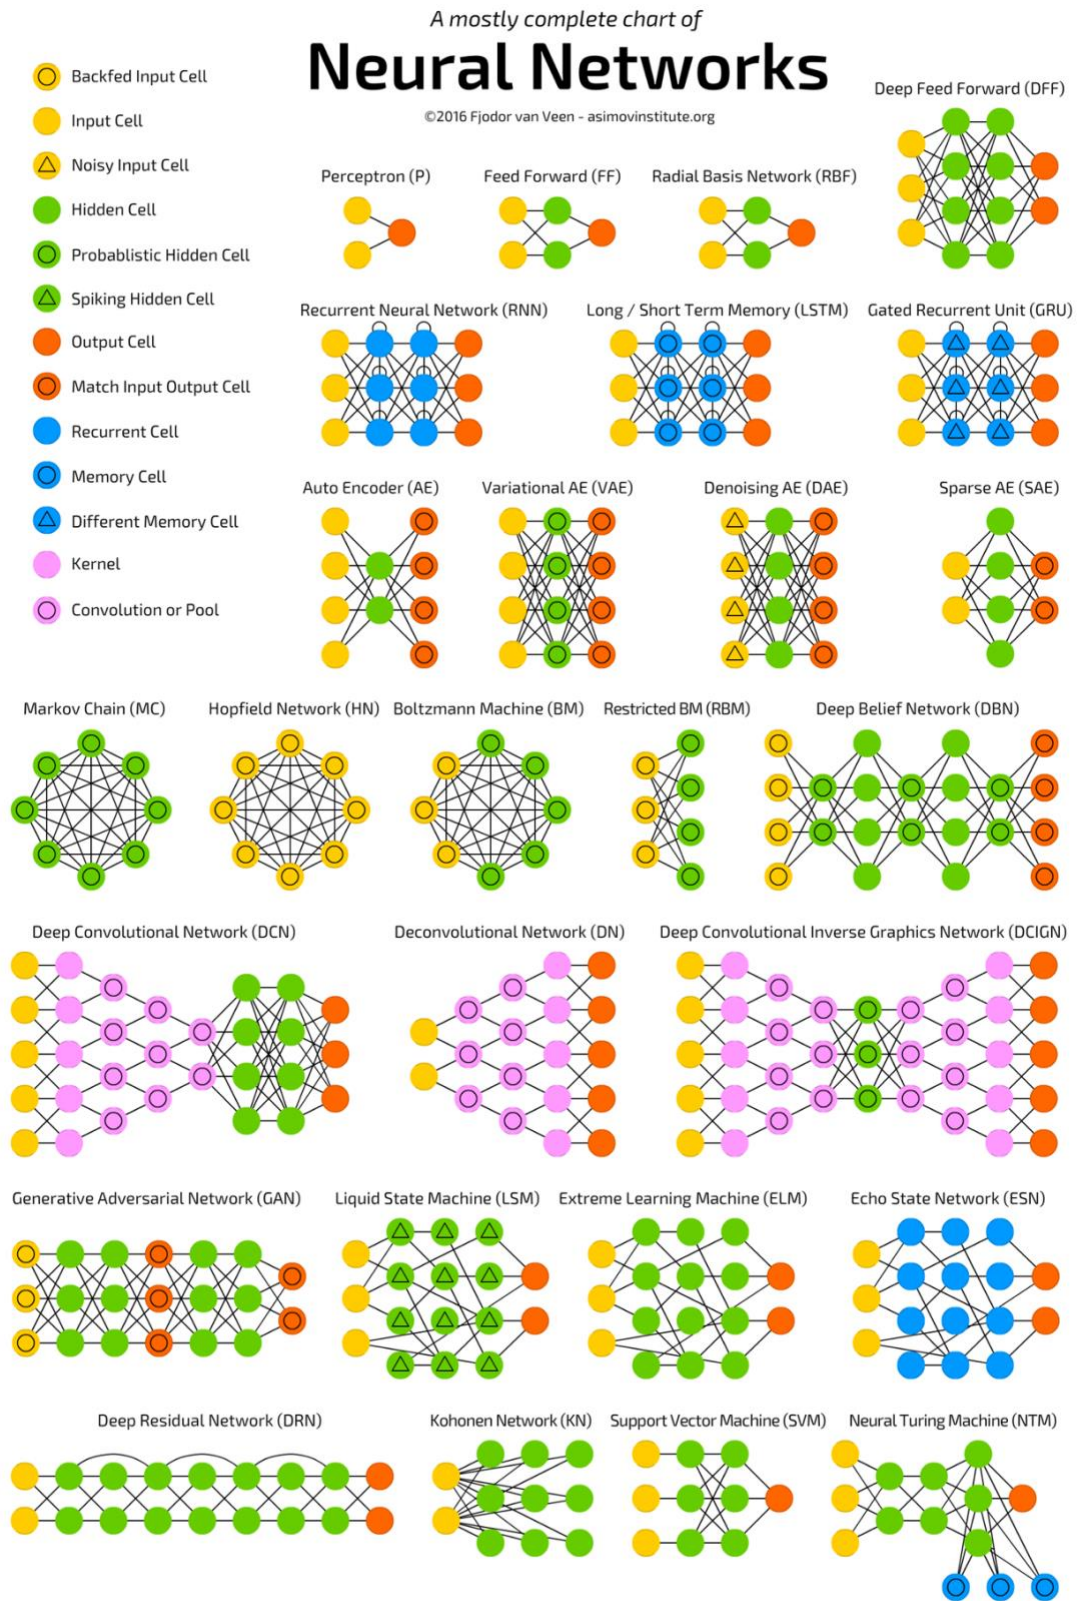
Legenda k příloze:

Zelená / LawnGreen / #7cfc00 = správné predikce pro dané datum

Červená / TomatoRed / #ff6347 = zbytečně pesimistická predikce (Aktuálně žádná z predikcí).

Modrá / DeepSkyBlue / #00bfff = příliš optimistická predikce (Aktuálně žádná predikce)

Příloha II. Infografický přehled neuronových sítí



Příloha III. Vybrané zdrojové kódy

1) Lineární regrese / konfigurace modelu v Tensorflow.js:

```
<!--region Aplikace-->
<script>
    async function learnLinear() {
        const model = tf.sequential(); //sekvenční: bez branchů/větvi.
        //výstupy do vstupů
        model.add(tf.layers.dense({units:1, inputShape: [1]})); //dense-
        //husté. všechny vstupy a výstupy propojeny s neurovem

        model.compile({
            loss: `meanSquaredError`, //definice LOSS Funkce
            optimizer: `sgd` //definice optimizační FUNKCE
        });

        const xs = tf.tensor2d([-4, -2, 0, 2, 4, 6], [6, 1]);
        const ys = tf.tensor2d([0, 1, 2, 3, 4, 5], [6, 1]);

        await model.fit(ys, xs, {epochs: 650});

        document.getElementById("output").innerText =
            model.predict(tf.tensor2d([17], [1,1]));
    }

    learnLinear();
</script>
<!--endregion-->
```

2) Klasifikace kosatců / trénování modelu

```
async function trainModel(xTrain, yTrain, xTest, yTest) {  
  ui.status('Trenuji model.. Prosim strpeni');  
  
  const params = ui.loadTrainParametersFromUI();  
  
  // Definice tpologie modelu: 2 husté vrstvy: 10 neuronů a 3 protože jsou 3  
  různé výstupy a pravděpodobnost se musí rovnat nule. Sekvenční model.  
  
  // Sigmoid (1|0 - klasifikace 1.layeru) a softmax (adds to 1) aktivace.  
  // Adam optimalizace  
  // categoricalCrossentropy funguje líp než RMSE (pro predikce cen - regrese)  
  const model = tf.sequential();  
  model.add(tf.layers.dense(  
    {units: 10, activation: 'sigmoid', inputShape: [xTrain.shape[1]]}));  
  model.add(tf.layers.dense({units: 3, activation: 'softmax'}));  
  model.summary();  
  
  const optimizer = tf.train.adam(params.learningRate);  
  model.compile({  
    optimizer: optimizer,  
    loss: 'categoricalCrossentropy',  
    metrics: ['accuracy'],  
  });  
  
  const trainLogs = [];  
  const lossContainer = document.getElementById('lossCanvas');  
  const accContainer = document.getElementById('accuracyCanvas');  
  const beginMs = performance.now();  
  
  // TRAIN: MODEL.FIT  
  const history = await model.fit(xTrain, yTrain, {
```

```

epochs: params.epochs,
validationData: [xTest, yTest],
callbacks: {
  onEpochEnd: async (epoch, logs) => {
    // Plot the loss and accuracy values at the end of every training
epoch.

    const secPerEpoch =
      (performance.now() - beginMs) / (1000 * (epoch + 1));

    ui.status(`Trenuji model... Odhadem ${
      secPerEpoch.toFixed(4)} vterin za epochu`)

    trainLogs.push(logs);

    tfvis.show.history(lossContainer, trainLogs, ['loss', 'val_loss'])
    tfvis.show.history(accContainer, trainLogs, ['acc', 'val_acc'])
    calculateAndDrawConfusionMatrix(model, xTest, yTest);

  },
}
});

const secPerEpoch = (performance.now() - beginMs) / (1000 * params.epochs);
ui.status(
  `Uceni modelu uspesne: ${secPerEpoch.toFixed(4)} vterin za epochu`);
return model;
}

```

3) MobileNet / predikce

```
const IMAGE_SIZE = 224;
const TOPK_PREDICTIONS = 10;

let mobilenet;

const mobilenetDemo = async () => {
  status('Nahrávám model...');

  mobilenet = await tf.loadModel(MOBILENET_MODEL_PATH);

  mobilenet.predict(tf.zeros([1, IMAGE_SIZE, IMAGE_SIZE, 3])).dispose();

  status('');

  const catElement = document.getElementById('cat');
  if (catElement.complete && catElement.naturalHeight !== 0) {
    predict(catElement);
    catElement.style.display = '';
  } else {
    catElement.onload = () => {
      predict(catElement);
      catElement.style.display = '';
    }
  }

  document.getElementById('file-container').style.display = '';
};
```