

VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

Fakulta informatiky a statistiky

Katedra informačního a znalostního inženýrství



Téma bakalářské práce:

Historie umělé inteligence – neuronové sítě

Vypracoval: Ondřej Šuchman

Vedoucí práce: Doc. PhDr. Petr Jirků, CSc.

Prosinec 2008

Abstrakt

Cílem mé bakalářské práce je zmapovat historický vývoj neuronových sítí od jejich počátku, za který lze považovat první matematický model neuronu v roce 1943, až po současnost a aplikaci neuronových sítí do „intelligentních“ přístrojů, které dokáží rozpoznávat znaky, grafické údaje nebo dokáží převádět anglicky psaný text do mluvené podoby (NETtalk). Pro dosažení tohoto cíle jsem pečlivě prostudoval literaturu uvedenou v kapitole „Literatura a zdroje.“ V první kapitole získáme teoretický přehled o oblasti umělé inteligence a neuronových sítí. Dále je pak práce přehledně řazena do pěti časových období, která byla pro neuronové sítě v kladném nebo záporném slova smyslu podstatná. U nejvýznamnějších objevů je podrobněji rozepsána jejich funkce a příklady použití. Tato práce si neklade za cíl úplný výčet neuronových sítí, na to by obsahově ani zdaleka nestačila. Podstatnější je pro ni demonstrace určitých typů sítí, jejich první použití, nejdůležitější algoritmy a také zmínka o některých významných aplikačních použitích.

Abstract

The main aim of my bachelor thesis is to map historical development of neural networks from the beginning (first mathematical model of neuron from 1943) to present and application of neural networks to „intelligent“ devices, which can recognize the patterns, graphical data or convert English written text to the oral form (NETtalk). I have carefully studied the literature named in the chapter „Literatura a zdroje“ in order to achieve this aim. In the first chapter there is the theoretical survey about the field of artificial intelligence and neural networks. Then the thesis is well-arranged to five periods, which were important for neural networks in either good or bad way. To the most important discoveries are dedicated more space and there is mentioned their functionality and using possibilities. There is not enough space on this thesis to cover all the neural networks ever made. The aim of the thesis is to demonstrate certain kinds of networks, their first usage, the most important algorithms and also to mention the significant applications of neural networks.

Poděkování

Rád bych poděkoval vedoucímu mé bakalářské práce, panu Doc. PhDr. Petr Jirků, CSc., za ochotu a kvalitní metodické vedení v průběhu práce a za literaturu, kterou mi v době zpracovávání poskytl.

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a použil pouze literaturu uvedenou v příloženém seznamu. Nemám námitek proti půjčení práce se souhlasem katedry ani proti zveřejnění práce nebo její části.

V Praze dne 3.prosince 2008

Ondřej Šuchman

Obsah

Úvod	8
1. Umělá inteligence a neuronová síť	9
1.1. Umělá inteligence	9
Inteligence	9
Umělá inteligence	9
Historie umělé inteligence	10
Zákony robotiky	12
1.2. Neuronové sítě	13
Biologická neuronová síť	13
Umělá neuronová síť	13
Využití umělých neuronových sítí	14
Dělení umělých neuronových sítí	15
2. Zrození neuronových sítí (1943-1956)	17
2.1. Jednoduchý model neuronu	17
2.2. Hebbovo pravidlo	19
2.3. Turingův stroj	19
Teorie čínského pokoje	20
2.4. SNARC	20
2.5. IBM 704	20
3. Zlatý věk (1956 – 1969)	22
3.1. Darmouth College	22
3.2. Perceptron	23
Učící pravidlo	23
Mark I Perceptron	24
3.3. Adaline	24
Madaline	26

3.4.	ART	26
3.5.	Minského a Pappertova kritika	28
4.	Nenaplnění předpokladů (1969 – 1982).....	29
4.1.	Cognitron a Neocognitron.....	29
5.	Rozmach a následný útlum (1982 – 1993).....	30
5.1.	Hopfieldova síť	31
5.2.	Kohonenova síť.....	33
5.3.	Boltzmannův stroj.....	33
	Boltzmannovo učení.....	34
5.4.	Backpropagation	34
5.5.	NETtalk.....	35
6.	Současnost (1994 - 2008).....	36
6.1.	Lavenbergův – Marquardtův učící algoritmus.....	36
6.2.	Deep Blue.....	37
7.	Budoucnost neuronových sítí	38
7.1.	Klasifikace	38
7.2.	Predikce.....	39
7.3.	Rozpoznávání.....	39
	Závěr.....	40
	Literatura a zdroje	41

Úvod

Když jsem se rozhodoval o tom, jakému tématu věnuji svůj čas při psaní bakalářské práce, byl jsem velice zaujat tématem umělé inteligence. Tento pojem je ovšem tak široký, že by na popsání jeho historie stěží stačila rozsáhlá publikace, natož pak bakalářská práce. Chtěl jsem se věnovat nějaké transdisciplinární oblasti, která by pokud možno souvisela s obory psychologie či neuropsychologie, kterým se mimo studia informatiky také věnuji. Téma neuronových sítí mě velice oslovilo. I když jsem věděl, že analogie s mozkem a jeho strukturou bývá v tomto oboru často velmi abstraktní, a že nebude jednoduché po technické stránce, rozhodl jsem se právě pro něj.

V současné době existuje na českém trhu několik publikací zabývajících se umělou inteligencí a neuronovými sítěmi. V každé z nich nalezneme několik stručných vět o jejich historii, ale žádná nepodává komplexnější pohled na neuronové sítě právě z hlediska historického. O prvním matematicky popsaném modelu neuronu je zpravidla pouze zmínka a přitom bez něj by dnešní sofistikované sítě a programy vůbec nevznikly.

První kapitola se zabývá teorií umělé inteligence a neuronových sítí, aby čtenář snáze pochopil následný text. Jsou zde uvedeny i oblasti, do kterých neuronové sítě zasahují. Od druhé kapitoly se již zabývám samotnou historií, kterou lze mapovat od roku 1943. Historie je přehledně rozdělena do pěti období, která se nacházejí v časovém intervalu 12-15 let.

Smyslem práce nebylo popsat všechny neuronové sítě, které byly v historii vytvořeny, ale spíše ukázat cestu, která získala této disciplíně současnou popularitu. Proto jsou v jednotlivých kapitolách popsány i některé významné algoritmy, bez kterých by se tento obor zastavil na bodu mrazu. Z aplikační oblasti neuronových sítí se, mimo závěrečné kapitoly o budoucnosti, zmiňuji také o souboji člověka s počítačem v šachu. Popisuji první počítač s tzv. pracovní pamětí (angl. Core Memory) IBM 704 a také počítač Deep Blue, které ve spojení s počítačovými programy dokázaly svými výkony zaujmout širokou veřejnost.

V závěru poukazuji na neuronové sítě, které dnes dokáží velice rychle klasifikovat a rozpoznávat data, grafické informace, umí předpovídat budoucí vývoj určitých systémů a také se dokáží samy učit a toto učení pak v praxi používat. Z toho pramení jejich aplikační nenákladnost a také široká ekonomická využitelnost.

1. Umělá inteligence a neuronová síť

1.1. Umělá inteligence

Intelligence

Intelligence je vlastností některých živých organismů, která se vyvíjela v průběhu dlouhého časového intervalu a dnes těmto organismům slouží k efektivní reakci na složité projevy prostředí, aktivnímu využití ve svůj vlastní prospěch a k dosažení svých cílů.

Umělá inteligence

Umělá inteligence (UI, angl. Artificial Intelligence, AI) je interdisciplinární vědou, která oficiálně vznikla v roce 1956, kdy byl tento pojem poprvé použit na konferenci v Darmouth v New Hampshire (USA). Je to věda, která je svým zaměřením velmi široká, nemá přesně vymezený předmět zkoumání. Umělá inteligence je spíše souborem metod, teoretických postupů a algoritmů používaných pro řešení určitých úloh.

Vzhledem k tomu, jaké široké spektrum možností umělé inteligence zahrnuje, nabízím několik definic od jiných autorů:

- 1) „UI je schopnost nějakého stroje imitovat inteligentní lidské chování.“¹
- 2) „UI je schopnost nějakého stroje simulovat lidský myšlenkový proces vykonáváním takových funkcí, které jsou obvykle spojovány s lidskou inteligencí, jako je rozumné uvažování, učení nebo sebezdokonalování.“²
- 3) „UI je vlastnost člověkem uměle vytvořených systémů vyznačujících se schopností rozpoznávat předměty, jevy a situace, analyzovat vztahy mezi nimi a tak vytvářet vnitřní modely světa, ve kterých tyto systémy existují, a na tomto základě pak účelně přijímat účelná rozhodnutí, za pomoci schopností předvídat důsledky těchto rozhodnutí a objevovat nové zákonitosti mezi různými modely nebo jejich skupinami.“³
- 4) „UI je věda o vytváření strojů nebo systémů, které budou při řešení určitého úkolu užívat takového postupu, který – kdyby ho dělal člověk - bychom považovali za projev jeho intelligence.“⁴
- 5) „Pod pojmem UI chápeme snahu člověka o vytvoření počítačových programů, které by se schopností rozhodovat se v předem neočekávaných situacích blížily uvažování a chování člověka a věrně jej napodobovaly.“⁵
- 6) „UI se zabývá tím, jak počítačově řešit úlohy, které dnes zatím lidé zvládají lépe.“⁶

¹ Webster's Encyclopedic Dictionary.

² ISO 2382 – 28 / 1988.

³ KOTEK a kol. (1983).

⁴ MINSKY, M. L., Massachusetts Institute of Technology (MIT, 1967).

⁵ SOWA, John Florian.

⁶ RICHOVÁ, E.

Historie umělé inteligence

Pokud pojmem umělou inteligenci z filozofického hlediska, sahá její historie velmi daleko. S otázkou, zdali „stroje mohou myslet“, přišli filozofové již v 17. století, jmenovitě Descartes, Hobbes, Pascal nebo La Metrie. Problém byl ovšem právě ve filozofii. Tito velikáni dob minulých řešili, zdali jsou stroje schopné myšlení, ale už neřešili, jakým způsobem toho lze dosáhnout. Tehdejší badatelé Blaise Pascal a Samuel Morland sestrojili v těchto letech mechanické kalkulátory, které uměly počítat a odečítat a Leibnitz dokonce takový, který uměl násobit a dělit.

Roku 1833 sestrojil Charles Babbage první mechanický počítač zvaný Analytical Engine. Ada Byron (nazývána někdy také Lady Lovelace), dcera proslulého básníka George Gordona Byrona, byla zaujata jeho prací a přeložila jeho přednášky, které doplnila o vlastní výklad a návrh, jak by mohl Analytical Engine počítat Bernoulliho čísla. Tento návrh se z určitého hlediska dá považovat za první počítačový program. Ada také prohlašovala, že počítače budou v budoucnosti schopny komponovat hudbu, vytvářet umělecká díla a budou používány k mnoha vědeckým i praktickým účelům. V něčem jistě předčila i vědce, kteří se o 123 let později sešli na konferenci v Darmouth (kap. 3.1). První počítač na nemechanické bázi, tzv. tabulátor, vytvořil roku 1890 Dr. Herman Hollerith. Tento tabulátor byl vytvořen pro sčítání lidu v USA. Fungoval na bázi elektrického proudu a při vyslání elektrického impulzu byla za každého obyvatele vždy přičtena jednička. Stále se ovšem ještě čekalo na něco nového. A to přišlo až ve 30. letech 20. století s rozvojem výpočetní techniky a nemalou měrou k tomu přispěly nové vědecké objevy na poli matematiky a fyziky.

Roku 1937 napsal Alan Turing článek „Countable numbers“, který byl jakýmsi předvojem Turingova stroje (kap 2.3). V roce 1943 přišli Warren McCulloch a Walter Pitts s jednoduchým matematickým modelem neuronu,⁷ což by se dalo považovat za počátek nejen neuronových sítí, ale i celé umělé inteligence. Toto období je „smrštěn“ nových algoritmů, nápadů a metod, které umožnily pokrok ve výpočetní technice. Dalším zlomovým rokem je rok 1950, kdy Alan Turing publikoval princip Turingova stroje v článku „Computing Machinery and Intelligence“ uveřejněný v časopise Mind, shromáždil argumenty proti inteligentním strojům a sám je postupně vyvrátil. V témže roce prohlásil John von Neumann, že počítače v blízké budoucnosti překonají intelektuální schopnosti člověka.

Největšími centry výzkumu umělé inteligence se staly Massachusetts Institute of Technology (MIT), Carnegie Mellon University (CMU) a Stanford Research Institute (SRI). Rok 1956 je oficiálně považován za vznik vědecké umělé inteligence, jelikož toho léta byl tento pojem poprvé představen na konferenci v Darmouth v New Hampshire v USA, kam se sjelo mnoho významných matematiků, fyziků, psychologů, neurologů, filozofů a vůbec lidí zájímajících se o vztah lidské mysli a strojů. Tehdejší předpovědi byly velmi odvážné, do roku 1970 měl počítač:

- 1) Být velmistrem v šachu (s několika otázkami lze říci, že se to podařilo roku 1997, kap. 6.2).
- 2) Odhalit nové významné matematické teoremy.
- 3) Porozumět přirozenému jazyku a být schopen sloužit jako překladatel.
- 4) Komponovat hudbu na úrovni klasiků.

⁷ V odborné literatuře se dosti často vyskytuje pojem „neuron“ místo správného „výkonný prvek sítě“. I já si zde dovoluji tento pojem používat z důvodu častého výskytu tohoto výrazu.

Tato konference znamenala skutečný boom ve vědeckém světě. A. Newell a H. Simon z Carnegie Mellon University zde představili první program využívající technik heuristického⁸ vyhledávání nazvaný Logic Theorist. Po Darmouthské konferenci bylo vytvořeno mnoho jazyků pro umělou inteligenci. Vůbec prvním byl ještě v roce 1956 jazyk IPL (Information Processing Language) pánů Newella, Shawa a Simona z MIT, který sloužil pro manipulaci se symboly. Nedlouho poté prezentovali tito vědci světu General Problem Solver (GPS), který má za úkol orientaci ve stavovém prostoru.⁹ Také vznikalo mnoho programů na rozpoznávání vzorů (angl. Pattern Recognition Programs) a programy hrající logické deskové hry, jako je dáma nebo šachy (viz Bernstein a aplikace jeho programu na počítači IBM 704, kap. 2.5). Roku 1957 vytvořil F. Rosenblatt perceptron (kap 3.2), který byl zdokonalením McCullochova a Pittsova jednoduchého modelu neuronu. Perceptron je schopný rozpoznávat grafické objekty na bázi expozimetru.¹⁰ Rosenblatt věřil, že pokud vytvoříme simulaci mnoha hustě propojených neuronů, můžeme také vytvořit inteligenci, což je předmětem disputací i v dnešní době, přičemž je tato teorie zpravidla podporována. Roku 1958 byl Johnem McCarthyem vytvořen jazyk LISP, dodnes jeden z nejpoužívanějších jazyků na poli umělé inteligence.

První program simulující nepřímou psychoterapii, ELIZA, vytvořil v roce 1966 Joseph Weizenbaum. Byl to zároveň první program používající přirozený jazyk. O rok později navrhl Colmerauer jazyk PROLOG, který je založen na tzv. rezolučním metodě odvozování v predikátové logice¹¹ a do dnešní doby je velice populární především v Evropě a v Japonsku. Po několika letech bylo ovšem jasné, že formulované cíle byly přehnané. Selhaly například pokusy o strojový překlad, které byly založeny na základních gramatických pravidlech. Zároveň se ukázalo, že většina metod je příliš univerzální na to, aby řešily vysoce specializované úlohy a tak koncem 60. let přichází krize, kterou ještě podpořili Minsky a Pappert svoji knihou Perceptrons (kap. 3.5).

V 70. letech dochází ke specializaci jednotlivých podoborů umělé inteligence a především ke vzniku velkého množství expertních systémů, např. PROSPECTOR z roku 1978, který sloužil k odhalování rudných ložisek. Velkou popularitu si získal tím, že v prvních šesti týdnech svého fungování odhalil ložiska v hodnotě 100 milionů amerických dolarů. Novější verzi Prospectoru se stal KAS, který pracuje s pravidly sítí vytvářenými v Prospectoru. Dalším expertním systémem je MYCIN, který slouží k diagnostice infekčních onemocnění krve a EMYCIN, který se stal jeho vylepšenou verzí. Emycin je dodnes používán v americké medicíně. Mezi rozpoznávacími systémy vyniká především SRI Vision Module autorů Agina a Gleasona, který dokáže rozpoznat součástky v průmyslové výrobě podle jejich obrysů. Na Elizu navazuje Winogradského SHRDLU, program pro komunikaci v přirozeném jazyce, který sice používá syntaktickou a sémantickou analýzu, ale jeho využití (povídání o světě kostek, jejich barvách a pozici) nepřináší takové praktické výsledky jako Eliza. Prvním systémem pro rozpoznávání řeči se stal HEARSAY II, který byl vyvinut na Carnegie Mellon University. Jinak je toto období považováno za období stagnace a nenaplnění předpokladů. Jedinými hmatatelnými výsledky bylo právě nasazení expertních systémů, zatímco ostatní podobory umělé inteligence se příliš nepohybovaly.

⁸ Heuristika je zvláštním způsobem řešení problémů. Je to postup vedoucí k nalezení optimálního způsobu řešení určitého problému bez znalosti daného algoritmu

⁹ Princip orientace ve stavovém prostoru spočívá ve vhodném procházení stavů řešené domény za účelem nalezení požadovaného stavu.

¹⁰ Expozimetr je zařízení určující jas zobrazované (fotografované, filmované) scény.

¹¹ Více o rezoluční metodě odvozování se lze dočíst v publikaci: JIRKŮ, P., VEJNAROVÁ, J.: Formální logika – Neformální výklad základů formální logiky. 2.vydání. Praha 2005, Oeconomica. 161 s. ISBN 80-245-0974-1. Str. 72-75.

Oživení zájmu o obor umělé inteligence přišlo na počátku 80. let. Přispělo k tomu také mnoho objevů na poli neuronových sítí (kap 5). Nadále se pokračuje ve vývoji nových a sofistikovanějších expertních systémů. Jedním z těchto expertních systémů je XCON firmy DEC, který sloužil ke konfiguraci počítačů VAX a podle odhadů ušetřil klientům něco okolo 40 miliónů dolarů na testovacích a výrobních nákladech. V roce 1981 byl v Japonsku vyhlášen projekt počítačů 5. generace založených na distribuované architektuře a zaměřených na zpracovávání nenumernických informací. Počítače této generace se zaměřují na rozsáhlé báze znalostí a jejich poloautomatické získávání pomocí učících mechanismů. Jejich největším dosavadním výsledkem je návrh sekvenčního inferenčního počítače PSI (Personal Sequential Inference Machine), pro nějž byl vyvinut sekvenční programovací jazyk KL0 (Kernel Language 0). Dále pak relační databázový počítač Delta Machine a jeho databázový jazyk Mandala. V USA je zahájen projekt firmy MCC a v Evropě projekt ESPIRIT, které mají za úkol především zpracování znalostí a rychlosti logických inferencí (až 1 miliarda za sekundu). V tomto období dochází k poměrně masivním investicím do nových projektů. Mnoho z nich je ovšem kritizováno pro svojí „neinteligenci“ nahrazovanou rychlostí.

V roce 1997 dochází k prolomení prvního cíle z Dartmouthské konference, a to když počítač Deep Blue (kap. 6.2) porazil v šachu mistra světa Gari Kasparova. Zajímavým pokusem je například projekt firmy ATR (Advanced Telecommunication Research), jehož úkolem je překlad telefonních hovorů mezi angličtinou a japonštinou v reálném čase.

Zákony robotiky

Jak už bylo řečeno, umělá inteligence se dlouhou dobu pohybovala pouze v oblasti science-fiction. V roce 1942, kdy o nějaké velké vědecké práci nebyla řeč,¹² napsal ruský spisovatel Isaac Asimov povídku Hra na honěnou (angl. Randaround), ve které vytyčil tři zákony, kterými se musí inteligentní stroj (robot) řídit.

- 1) Robot nesmí ublížit člověku, ani svou nečinností dopustit, aby člověku bylo ublíženo.
- 2) Robot musí uposlechnout příkazů člověka, kromě případů, kdy by uposlechnutí rozkazu bylo v rozporu s prvním zákonem.
- 3) Robot musí chránit vlastní existenci, pokud tato ochrana není v rozporu s prvním a druhým zákonem.¹³

Sám autor později přidal ještě nultý zákon, který říká, že „robot nesmí ublížit lidstvu, ani svou nečinností dopustit, aby lidstvu bylo ublíženo.“ Tyto zákony by samy vydaly na celou publikaci. Smyslem této části bylo pouze zformulovat myšlenku, že ačkoliv je naším cílem vyvíjet stále sofistikovanější stroje, nikdy bychom se neměli dostat do situace, abychom se díky své vlastní minulé činnosti báli o budoucí existenci člověka.


¹² První matematický model neuronu byl popsán až v roce 1943, vznik umělé inteligence jako vědní disciplíny datujeme až o 13 let později.

¹³ ZELINKA, I.: Umělá inteligence. Hrozba nebo naděje? Praha, BEN – technická literatura 2003. 144 s. ISBN 80-7300-068-7. Str. 28.

1.2. Neuronové sítě

Biologická neuronová síť

Lidský mozek obsahuje zhruba 100 – 150 miliard neuronů.¹⁴ Množství propojení mezi nimi je mnohokrát více, jelikož každý neuron je napojen na přibližně 10 tisíc dalších neuronů. Biologický neuron se skládá z těla (soma, cell body), axonu, dendritů a synaptických zakončení. Samotný proces přenosu vzruchu probíhá tak, že neuron přijme (dostatečně silný) elektrochemický impulz pomocí dendritů, ten je poté veden do těla a poté prostřednictvím axonu dojde až k synaptickým zakončením, která tento impulz postoupí dále.¹⁵



Obrázek 1¹⁶

Umělá neuronová síť

Již Aristoteles hlásal, že „celek je více než souhrn jeho částí“ a na této myšlence je vlastně neuronová síť založena. V minulé podkapitole jsem hovořil o biologické neuronové síti. U umělé neuronové sítě probíhá proces přenosu informace (impulzu) analogicky jako u sítě biologické, pouze pro tento přenos používá výpočetní operace.

Umělá neuronová síť (angl. Artificial Neural Network, ANN) sestává z mnoha neuronů, jejichž vzájemným propojením a přiřazením určitých vah lze řešit obtížné výpočetní operace, které by byly pro člověka příliš náročné.

¹⁴ Tyto údaje se v podstatě v každé publikaci liší. Např. Zelinka uvádí ve své knize „Umělá inteligence. Hrozba nebo naděje?“ údaj okolo 25 miliard a takto bychom mohli pokračovat dále. Pravdou je, že v současné době je i takto přibližný počet těžko zjištělný.


¹⁵ Neural Networks – Biology. <http://cse.stanford.edu/class/sophomore-college/projects-00/neural-networks/Biology/index.html> [16.10.2008].

¹⁶ Neural Networks – Neuron. <http://cse.stanford.edu/class/sophomore-college/projects-00/neural-networks/Neuron/index.html>. [12.11.2008].

Pro ujasnění tohoto pojmu nabízím i několik definic z českých a zahraničních zdrojů:

- 1) Umělá neuronová síť je síť mnoha jednoduchých procesorů, navzájem bohatě propojených. Graf propojení se často nazývá topologie sítě. Procesory nazýváme neurony proto, že velice zjednodušeně modelují skutečné neurony v centrální nervové soustavě a jejich formální, popř. technický, návrh je mnohdy inspirován vlastnostmi mozku a periferního nervstva.¹⁷
- 2) Umělá neuronová síť je paralelní distribuovaný systém výkonných prvků modelujících biologické neurony, účelně uspořádaný tak, aby byl schopen požadovaného zpracování informací.¹⁸
- 3) Umělá neuronová síť je systém sestávající z výpočetních jednotek – neuronů (neuron, node, unit), které jsou mezi sebou vzájemně propojeny spoji ohodnocenými váhami a tímto propojením.¹⁹

Na rozdíl od biologických elektrických signálů, umělá neuronová síť používá k tomuto signálu početní hodnoty. Pokud hodnoty vstupů (vstupní vektor) společně dosáhnou určité předem stanovené prahové hodnoty, dojde k předání impulzu.



Obrázek 2²⁰

Využití umělých neuronových sítí

Neuronové sítě slouží k řešení mnoha praktických problémů napříč celou řadou oborů. Společným jmenovatelem těchto problémů je chaotičnost a složitost. Prakticky neexistuje jiný způsob, pomocí kterého by bylo možné řešit takovéto situace kvalitněji a rychleji než právě za pomoci umělých neuronových sítí. Oblastmi, kam neuronové sítě pronikají, jsou především:²¹

¹⁷ MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence (Díl 1). 1.vydání. Praha 1993, Academia. 264 s. ISBN 80-200-0496-3. Str. 217.

¹⁸ NOVÁK, M. a kol.: Umělé neuronové sítě. Teorie a aplikace. 1.vydání. Praha 1998, C. H. Beck. 382 s. ISBN 80-7179-132-6. Str. 144.

¹⁹ MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence (Díl 4). 1.vydání. Praha 2003, Academia. 475 s. ISBN 80-200-1044-0. Str. 204.

²⁰ Neural Networks – Neuron. <http://cse.stanford.edu/class/sophomore-college/projects-00/neural-networks/Neuron/index.html>. [12.11.2008].

²¹ Neuronové sítě mají samozřejmě uplatnění v mnoha dalších oblastech. Podle mého názoru jsou tyto oblasti těmi nejpodstatnějšími.

- 1) **Bezpečnost** (systémy pro ochranu objektů).
- 2) **Obchod** (předpověď vývoje akcí a chování jiných systémů).
- 3) **Medicína** (výzkum mozkových funkcí).
- 4) **Meteorologie** (předpověď počasí i pravděpodobný budoucí průběh globálního oteplování).
- 5) **Průmysl** (součást některých expertních systémů, samoobslužné stroje).
- 6) **Robotika** (vyhodnocení situace robota a jeho reakce na vzniklou situaci, kyborgové).²²
- 7) **Vojenství** (uplatnění v mnoha aplikacích, například radarové nebo sonarové signály).

Dělení umělých neuronových sítí

Umělé neuronové sítě můžeme rozdělit podle několika kritérií. Je to především primární založení, počet vrstev, typ propojení, způsob přenosu signálu, typ algoritmu učení, styl učení sítě a typ neuronů.

1) Podle primárního založení

- a) *Sítě biologického typu* – sítě, které se zaměřují na ověřování některých hypotéz o reálných biologických systémech, jako jsou například struktury lidského mozku nebo funkce smyslových aparátů.
- b) *Aplikační sítě* – sítě, u kterých není biologická similarita²³ primárním faktorem, ale jde spíše o efektivní technickou realizaci.

2) Podle počtu vrstev

- a) *Sítě jednovrstvé* (Single-layer Networks) – např. Hopfieldova síť (kap 5.1) nebo Kohonenova síť (kap 5.2).
- b) *Sítě dvou nebo vícevrstvé* (Multi-layer Networks) - Perceptron, ART a některé sítě používající algoritmus backpropagation (kap 5.4).

3) Podle typu propojení (pouze vícevrstvé sítě)

- a) *Sítě s mezivrstvovými spoji* (Interlayer Connections) – sítě, které mají určitá propojení s neurony různých vrstev (předcházejících či následujících). Zvláštním případem těchto sítí jsou ty s úplným propojením všech neuronů, které se v praxi používají především pro klasifikaci nebo predikci. U sítí s neúplným propojením se zase může jednat o redundanci, tj. odstranění všech nadbytečných spojů za účelem zefektivnění procesu.
- b) *Sítě s laterálním propojením* (Lateral Connections) – sítě se spoji pouze mezi výkonnými prvky téže vrstvy. Jsou zde propojeny pouze neurony téže vrstvy. Používají se především v sítích se soutěžním učením.²⁴

²² Kyborg je složeninou slov „kybernetický organismus“. Jedná se o živou bytost obohacenou o elektronické nebo mechanické součástky.

²³ Tj. podobnost.

4) Podle způsobu přenosu signálu (pouze vícevrstvé sítě)

- a) *Sítě s dopředným šířením* (Feed-forward Networks) – sítě, u kterých se signál šíří směrem dopředu, tzn. z vrstvy n do vrstvy $n + 1$.
- b) *Sítě zpětnovazební* (Feed-back Networks) – sítě, u kterých se signál šíří směrem zpět, a to z vrstvy n do vrstvy $n - i$, kde $i = 1, 2, \dots, n$.

5) Podle typu algoritmu učení

- a) *S učitelem* – k učení jsou na vstupu používány vzory, jejichž následný reálný výstup je porovnáván s výstupem očekávaným a podle velikosti chyby jsou následně upravovány parametry adaptivního souboru. Tento způsob je nejnáročnější z informačního hlediska. Jsou to např. sítě s algoritmem backpropagation.
- b) *S učením pod dohledem* (Supervised Learning) – v určitých intervalech je prováděno hodnocení přiměřenosti reálného výstupu v porovnání s výstupem očekávaným. Z informačního hlediska je méně náročný než typ první.
- c) *Bez učitele* – sítě tzv. samo se organizující, které mají nejbližší k biologické analogii. Samy si třídí informace, což může být někdy na úkor požadovaného výstupu. Z informačního hlediska jsou velmi nenáročné. Je to např. Hopfieldova síť.

6) Podle stylu učení

- a) *S učením deterministickým* – sítě, ve kterých jsou váhy všech vstupů na začátku přesně určeny (determinovány), např. sítě používající algoritmus backpropagation.
- b) *S učením stochastickým* (váhy jsou určeny víceméně chaoticky) – sítě, u kterých jsou počáteční váhy nastaveny více méně chaoticky, případně je jejich hodnota nějakým způsobem omezena, ale není přesně stanovena.

7) Podle typu neuronů

- a) *Sítě homogenní* – všechny neurony v síti jsou stejného typu.
- b) *Sítě heterogenní* – neurony v síti jsou odlišného typu.

²⁴ Soutěžní učení spočívá v tom, že před každým cyklem učení je proveden výběr mezi uvažovanými neurony. Ten z nich, který v soutěžení s ostatními zvítězí, získá také možnost provést modifikaci svých vah.

2. Zrození neuronových sítí (1943-1956)

Za první etapu na cestě umělé inteligence lze považovat období od vzniku prvního jednoduchého modelu neuronu až do konference v americkém městě Darmouth. Je to období, které ještě nelze oficiálně považovat za vědecké, nicméně pro umělou inteligenci a potažmo neuronové sítě je klíčové. Období, ve kterém se definují pojmy a vzniká mnoho návrhů. Uvažuje se o tom, „co a jak by se dalo zkonstruovat“ a také vznikají první publikace, často i vědecko-fantastické, o tom, co nám tato oblast může přinést a nabídnout, zároveň ale také o tom, čím může být člověku nebezpečná.

2.1. Jednoduchý model neuronu

Rok 1943 je mnohými považován za vznik neuronových sítí a umělé inteligence vůbec. V tomto roce neurofyziolog Warren McCulloch a matematik Walter Pitts matematicky popsali jednoduchý model neuronu v práci „A Logical Calculus of Ideas Immanent in Nervous Activity“. Tento model je také znám pod názvem „lineární prahová brána“ (angl. Linear Threshold Gate). Tito pánové poukázali na to, že propojením většího množství takovýchto neuronů je možné realizovat v podstatě jakoukoliv funkci. Tento popis se stal základním stavebním kamenem pro budoucí vývoj neuronových sítí. O 14 let později na tento jednoduchý model navázal Franc Rosenblatt, když jeho zobecněním pro reálný obor parametrů navrhl stěžejní model neuronových sítí, tzv. perceptron (viz 3.2.), který sloužil pro vytváření vícevrstevných perceptronových sítí.

Pro jednoduchý model neuronu lze použít následující rovnice:

$$Sum = \sum_i^N I_i W_i ,$$


$$y = f(Sum) ,$$

kde Sum je vážená suma ,

I jsou vstupy (angl. Inputs),


W jsou váhy (angl. Weights) jednotlivých vstupů nabývající hodnot z oboru (0, 1) nebo (-1, 1) a

y je výstup, vzniklý aplikací lineární skokové funkce f (angl. Linear Step Function) na první rovnici.



Obrázek 3 - Lineární prahová funkce

Na obrázku 3 vidíme, že pomocí tohoto modelu neuronu lze provést klasifikaci do dvou různých tříd, výstup je tedy vždy binární. Písmenem T na obrázku je označena prahová konstanta.



Obrázek 4 - Jednoduchý model neuronu²⁵

Pojďme si nyní ukázat, jak vlastně jednoduchý model neuronu, který je zobrazen na obrázku 4, funguje. Pro lepší znázornění jsem si dovolil omezit hodnoty vah vstupů pouze na 0 a 1. Níže uvedená tabulka ukazuje aplikaci logických funkcí na jednoduchý model neuronu. Předpokládejme, že každý jednotlivý vstup I má přiřazenou právě jednu váhu W . Pak použijeme klasickou výrokovou logiku, kde 1 znamená pravdu (true) a 0 znamená nepravdu (false), přičemž výstup je závislý na použité logické spojce. Pokud ze zadaných vstupů vznikne tautologie, čili pokud bude výstup pravdivý dojde k dosažení nebo přesažení tzv. prahové hodnoty T (angl. Threshold). Do tabulky jsem uvedl logické funkční spojky AND, OR a XOR, abychom lépe viděli, kdy bude neuron přenášet signál (výstup bude 1) a kdy ne (výstup bude 0). Výstup 1 pracuje s funkcí AND, kdy je k přenesení signálu potřeba, aby všechny hodnoty vstupů byly pravdivé (1). Výstup 2 ukazuje funkci OR, při které pro pravdivý výsledek stačí, aby alespoň jeden ze vstupů nabýval hodnoty 1. První větší problém přichází u jednoduchého modelu neuronu při použití funkční spojky XOR (nonekvivalence neboli vylučovací disjunkce). Tento model je příliš jednoduchý na to, aby dokázal vyřešit funkci XOR pro klasifikaci objektů do více než dvou tříd. Tato funkce při použití jednoho neuronu není totiž lineárně separabilní.

Váha vstupu 1	Váha vstupu 2	Výstup 1 (AND)	Výstup 2 (OR)	Výstup 3 (XOR)
0	0	0	0	0
0	1	0	1	1
1	0	0	1	1
1	1	1	1	0

Obrázek 5 – Aplikace logických funkcí na jednoduchý model neuronu

²⁵ 2. 3. 1. The McCulloch–Pitts Model of Neuron. <http://www.ece.utep.edu/research/webfuzzy/docs/kk-thesis/kk-thesis-html/node12.html>. [27.10.2008].

2.2. Hebbovo pravidlo

V roce 1949 vydal kanadský psycholog Donald Olding Hebb knihu *The Organization of Behaviour: A Neuropsychological Theory* (Struktura chování: Neuropsychologická teorie). Hebb popsal v této knize tzv. Hebbovo (učící) pravidlo, které lze definovat takto: „Pokud je axon (nervový výběžek) buňky A dostatečně blízko, aby působil na buňku B a opětovně nebo opakovaně měl podíl na její aktivaci, vznikají v jedné nebo v obou buňkách efektivní růstové procesy nebo metabolické změny takové, že je zvýšena efektivita.“ V jednodušší formě můžeme tvrdit, že dva vzájemně interagující (synapsemi propojené) neurony mají větší sílu, než by měl každý zvlášť. Jedná se v podstatě o možnost regulovat jednotlivé váhy k dosažení kýženého výsledku. Pokud přidáváme váhu více neuronům navzájem, jejich výsledný výstup nebude pouze váha přidaná, nýbrž vyšší, pokud jsou neurony aktivní. Hebbovo pravidlo má značná omezení při praktické použitelnosti, nicméně díky němu vzniklo mnoho dalších pravidel, algoritmů a proto ho z historického hlediska považujeme za velmi důležité. Jednou ze sítí, která by bez Hebba vznikala jen stěží, je tzv. Hopfieldova síť.

2.3. Turingův stroj

Mohou stroje myslet? To je otázka, která trápila vědce v dobách minulých a díky nekonsolidované definici inteligence trápí mnoho z nich dodnes. Alan Turing navrhl v roce 1950 test, publikovaný v článku „Computing Machinery and Intelligence“ časopisu *Mind*, který má za úkol zjistit, zdali je počítač inteligentní, zdali dokáže myslet.

V původní verzi vycházel z tzv. imitační hry, kdy máme tři místnosti, v jedné je muž, ve druhé žena předstírající muže (nebo naopak) a ve třetí soudce. Dále je mezi nimi nestranná osoba přenášející lístky a zajišťující tím vzájemnou komunikaci. Pokud se ženě podaří přesvědčit soudce o tom, že je muž, prošla úspěšně testem. Turing dal ovšem testu diametrálně odlišný rozměr. Namísto dvou odlišných pohlaví je v jedné místnosti člověk, ve druhé počítač a ve třetí soudce, kteří vzájemně komunikují buď opět přes nestrannou osobu nebo přes jiný počítač. Pokud je úspěšnost počítače vyšší než 50%, pak ho podle Turingova testu můžeme prohlásit za inteligentní. Později byl tento test upraven do podoby, kdy jsou jen dvě místnosti, jedna soudcova a jedna, kde je buď člověk nebo počítač. Soudce pak musí rozhodnout, kdo nebo co se v dané místnosti nachází. Sám Turing shromáždil několik argumentů proti své teorii, které postupně úspěšně vyvrátil. I přesto se začala brzy objevovat kritika, že test samotný nevypovídá nic o inteligenci počítače, nýbrž pouze o jeho schopnosti simulovat myšlení a navíc se zaměřuje pouze na schopnosti komunikace a používání jazyka, což samotné nelze považovat za projev inteligence. Navíc pokud by měl počítač k dispozici seznam všech otázek a odpovědí na ně (což je ovšem nereálné), zúžil by se problém na pouhé vyhledávání v seznamu.

Už Turing přišel s myšlenkou programů schopných se samostatně učit. Nicméně přidal důležitý komentář, že je velmi obtížné zkonstruovat přímo „dospělého člověka“, což je problém, který se přímo týká neuronových sítí. Právě ty postupem času vzájemnou interakcí posilují svoje znalosti a svoji „inteligenci“ a dochází zde k analogii biologické evoluce, kdy je potřeba spousta času pro zdravý a optimální vývoj. Turing předpovídal, že jeho test bude prolomen roku 2000. V tomto se mýlil. Ve Velké Británii probíhá každoročně soutěž, kde se programátoři snaží projít Turingovým testem. Do roku 2008 se to zatím žádnému nepodařilo a proto se vítězem stal vždy ten, jehož počítač dokáže člověka imitovat nejdůvěryhodněji.

Teorie čínského pokoje

Turingův test (stroj) měl již od svého vzniku mnoho kritik. Za tu nejznámější lze považovat Searlovu „teorii čínského pokoje“, kterou autor uveřejnil ve své publikaci *Minds, Brains and Programs* (Mozek, mysl a program) v Cambridgi roku 1980. Podle této teorie by v místnosti mohl být člověk, který umí pouze anglicky, ale má k dispozici všechny výrazy, slovní spojení a gramatiku čínského jazyka a instrukce o tom, jak v tomto jazyce odpovídat. Byl by mu zaslán požadavek v čínštině a on by po určité době byl schopen v tomto jazyce odpovědět, ačkoliv o něm v podstatě nic neví. Tento argument lze považovat za poměrně silný, nicméně přichází fundamentální otázka: Co je to vlastně inteligence? To, že nám stroj dokáže přesně zodpovědět většinu našich otázek, ještě neznamená, že je inteligentní. Pokud má dostatečné informace, dokáže nám odpovědět na obtížné, nějakým způsobem specializované (například technologické nebo fyzikální) otázky s naprostou samozřejmostí. Dokáže ale toto člověk s minimálním vzděláním? Považovali bychom ho potom za neinteligentního? *Homo sapiens sapiens* je člověk rozumný, jinými slovy člověk disponující určitou inteligencí a proto mu nemůžeme tuto vlastnost odebrat díky jeho neznalosti určité oblasti. Stanislaw Lem „radí“ ve své knize *Tajemství čínského pokoje* Searlovi, aby se nechal zavřít do pokoje s návodem a příběhem, omezeným třeba na pouhé verše „Kočka leze dírou, pes oknem, nebude-li pršet, nezmoknem“ a je mu položena otázka na velikost díry, rasu psa, druh okna a zda-li mají nějaký význam nebo jsou v příběhu pouze kvůli veršům. Searle by si pravděpodobně s takovou situací rady nevěděl.²⁶ Samotná podstata je ale v tom, že z takového testu nic neplyne, záleží totiž na kontextu.

Přestože tato kritika byla ve své době velmi populární a Turingův test má několik dalších nedostatků, zatím nikomu se ho nepodařilo zcela popřít či přijít s lepší ideou, a tak je do dnešní doby stále považován za hranici inteligentního myšlení.

2.4. SNARC

Marvin Lee Minsky a Dean Edmonds sestrojili v roce 1951 první stochastickou neuronovou síť, neuropočítač zvaný SNARC (Stochastic Neural Analog Reinforcement Calculator), který byl založen na zesílení koeficientů simulovaného synaptického přenosu. Nicméně je potřeba podotknout, že SNARC nebyl ještě počítačovou simulací, nýbrž pouze první neuronovou sítí schopnou se učit.

2.5. IBM 704

Massachusetts Institute of Technology (MIT) a firma International Business Machines (IBM) byly v těchto letech hlavními technologickými institucemi. Spousta nadějných absolventů z MIT se vrhala do IBM, kde jim bylo poskytnuto velmi dobré zázemí pro jejich vědeckou činnost. Jedním z nich byl také Nathaniel Rochester,²⁷ jehož tým byl v roce 1954²⁸ pověřen prací na problému rozpoznávání znaků, teorie informace a teorie spínacího obvodu. Jedním z výstupů tohoto projektu se stal IBM 704, který byl historicky první simulací hypotetické neuronové sítě.

²⁶ LEM, S.: *Tajemství čínského pokoje*. Mladá fronta 1999, Edice Kolumbus. 200 s. ISBN 80-204-0826-6. Str. 92-93.

²⁷ Jedním z ukázkových případů spolupráce těchto dvou institucí byl právě Rochester. Na MIT promoval roku 1941 a o 7 let později, naplněných vědeckou prací na MIT a v Sylvania Electric Products, získal místo v IBM.

²⁸ IBM Archives – 1954. http://www-03.ibm.com/ibm/history/history/year_1954.html. [27.10.2008].

IBM 704 byl vylepšenou verzí počítače IBM 701, který používal pracovní paměť. Oproti svému předchůdci měl propracovanější architekturu. Dokázal zpracovat až 40 000 instrukcí za sekundu a až miliardu během jednoho dne. Více než samotný počítač a jeho architektura zaujmou výsledky, kterých dosáhl při používání v jiných institucích. V následujících pěti letech od vydání ho bylo prodáno 123 kusů.

Například díky němu, nebo přinejmenším s jeho přispěním, vznikly programovací jazyky Lisp a Fortran. Roku 1957 použila Smithsonian Astrophysical Observatory IBM 704 ke sledování trasy měsíce. Byl také použit Johnem Larry Kellym juniorem spolu s jeho hlasovým syntetizátorem pro úpravu písně Daisy Bell, kterou také zpívá počítač HALL 9000 v Kubrickově filmu 2001: Vesmírná odysea (angl. 2001: A Space Odyssey). Toto se událo až v 60. letech 20. století, ale primární význam je právě v roce 1954 a vytvoření počítače IBM 704. Dalším důležitým polem využití je teorie her. Například Ed Thorp použil IBM 704 jako nástroj při vyvíjení dokonalé strategie ve hře black jack.

Roku 1958 Alex Bernstein a jeho spolupracovníci vytvořili počítačový program pro IBM 704. Partie probíhala tak, že Bernstein fyzicky hrál za sebe i za soupeře, ovšem mentálně to byl souboj člověka s počítačem. Bernstein vždy odehrál, sdělil svůj tah počítači a nechal ho „přemýšlet“ nad protitahem. Ten měl před sebou zhruba 30 možných tahů.²⁹ Po položení osmi předběžných otázek (angl. Preliminary Questions) a následnému vyhodnocení zbylo 7 možných tahů k hlubší analýze. Každý z těchto 7 kroků je zkoumán na 4 tahy dopředu, zvažujíc možné odpovědi soupeře a následné protitahy. Takto dokáže stroj zvážit 2800 různých pozic během osmi minut a následně vytiskne pozici, kterou si přeje po svém odehrání, vše samozřejmě podle pravidel šachu. Stroj také dokáže rozpoznat tahy člověka, které jsou proti pravidlům, a při zadání takového požadavku odpoví heslem „please check last move“ (zkontrolujte poslední tah, prosím). Tento program spolu se strojem IBM 704 byl na svou dobu hodně pokrokový, slabšího nebo průměrného hráče dokázal porazit, ovšem dobrému hráči ještě konkurencí nebyl. V tomto konkrétním případě se hra dostala do 21. tahu, kdy Bernstein chytře zaútočil, stroj reagoval velmi neinteligentně, přičemž po dalším tahu zhodnotil svoji situaci jako bezvýchodnou a musel rezignovat. Problém je v tom, že tento stroj bude neustále dělat stejné chyby, jaké udělal v této prohrané partii, čili „není schopen se z chyb poučit“, což je fundamentální reakce inteligentních systémů. Bernstein ovšem věřil, že jednoho dne se tuto bariéru podaří prolomit a program spolu s počítačem budou schopny se poučit z chyb, kterých se dopustily v předchozích partiích a budou se tak samy dále zdokonalovat.

²⁹ Počítejme téměř se začátkem šachové partie. Další údaje se shodují s testovanou situací, která je k dispozici ve videoformátu na: http://www.youtube.com/watch?v=iT_Un3xo1qE. [27.10.2008].

3. Zlatý věk (1956 – 1969)

Těžko říct, zdali toto období lze nazvat nejpodstatnějším ze všech. V roce 1956 takřka nikdo nepochyboval o tom, že se rodí disciplína, která změní svět radikálním způsobem. Dnes nemůžeme rozhodně tvrdit, že by tato tvrzení nebyla pravdivá, nicméně tehdejší očekávání byla z dnešního pohledu velmi nadnesená. Vychází ohromné množství publikací o umělé inteligenci. Mnoho laiků také omezuje umělou inteligenci pouze na robotiku a šílené představy o ovládnutí člověka robotem. Vědci se předhánějí v odhadech, za jak dlouho k něčemu takovému skutečně dojde. Každopádně je to období, které bylo pro tento obor důležité i z hlediska pochopení, že stanovení nějakého cíle bez předešlé analýzy může i s tak potencionálně perspektivním oborem hodně otrást.

3.1. Darmouth College

Rok 1956 je pro neuronové sítě i pro celou umělou inteligenci významným milníkem. Tohoto léta se totiž na Darmouth College ve státě New Hampshire (USA) sešli vědci, kteří během 2 měsíců dali oficiálně vzniknout umělé inteligenci. Navrhovateli této významné události byli již v roce 1955:

J. McCarthy z Darmouth College,

M. L. Minsky z Harvard University,

N. Rochester z I.B.M. Corporation a

C. E. Shannon z Bell Telephone Laboratories,

kterí vytyčili cíle, kterých by mělo být během léta dosaženo. V podstatě šlo o možnosti, jak naučit počítače používat jazyk, abstrakci a řešit takové problémy, které byly prozatím vyhrazeny pouze člověku. Vytvořili seznam vědců, kteří by se měli události zúčastnit a být schopni při vzájemné kooperaci některé nebo všechny tyto cíle splnit. Vědci byli dotázáni, v jaké oblasti by chtěli pracovat a podle svých preferencí byli také rozděleni do jednotlivých týmů. O podporu pro tento projekt byla požádána Rockefellerova nadace, která se tohoto úkolu štědře zhostila a poskytla na akci nemalé finanční prostředky. Obecně byla očekávání velmi vysoká a otázky typu „za jak dlouho bude počítač schopen přemýšlet stejně jako člověk, nebo za něj vykonávat mnoho obtížných činností,“ byly na denním pořádku. Nikdo se příliš nepozastavoval nad tím, jak složitý proces bude třeba podstoupit a zdali je vůbec něco takového možné. Bylo předpovězeno, že do roku 1970 má počítač:

- 1) Být velmistrem v šachu (s několika otázkami lze říci, že se to podařilo roku 1997, viz. kap. 6.2).
- 2) Odhalit nové významné matematické teorémy.
- 3) Porozumět přirozenému jazyku a být schopen sloužit jako překladatel.
- 4) Komponovat hudbu na úrovni klasiků.

Co se týče neuronových sítí, byla na Darmouthské konferenci postavena otázka, jak by bylo možné uspořádat sadu hypotetických neuronů tak, aby společně a efektivně pracovaly. Mnoho práce na tomto poli odvedli Clark, Farley, Holland, McCulloch, Minsky, Pitts, Rashevsky a jeho tým,

Rochester, Uttley a několik dalších. Některé otázky byly vyřešeny, nicméně stále byl potřeba rozsáhlejší teoretický základ.³⁰

3.2. Perceptron

„V roce 1957 Franc Rosenblatt vytvořil na Cornell Aeronautical Laboratory model tzv. perceptronu, který je zobečněním McCullochova a Pittsova modelu neuronu pro reálný číselný obor parametrů.“³¹ Tento model je stále ještě jednovrstvou neuronovou sítí, která je určena pro dichotomickou klasifikaci.³² Perceptron předpokládá lineárně separabilní třídy na vstupech a vzniká tak problém s funkcí XOR, jelikož by výstup musel měnit svou hodnotu při každé změně vstupu. I přesto se perceptron stal základem neuronových sítí, u kterých plní funkci obecného výpočetního prvku. K jeho aplikaci přispěly velkou měrou myšlenky v 80. letech minulého století, kdy byl vyřešen problém nelineární separability aplikací více než jedné vrstvy sítě (kap. 5). Vnitřní potenciál perceptronu počítáme podle následujících vztahů (druhá rovnice je aktivační funkcí):

$$\varsigma = \sum_{i=1}^n w_i x_i - \theta = \sum_{i=0}^n w_i x_i ,$$

$$f(\varsigma) = \frac{1}{1 + e^{-\lambda \varsigma}} ,$$

kde λ je parametr strmosti (angl. Gain).

Učící pravidlo

Předpokládejme, že máme několik učících příkladů sestávajících ze vstupního vektoru x a požadovaného výstupu $d(x)$, který je většinou 1 nebo -1. Učící pravidlo je velice jednoduché a můžeme ho formulovat takto:

- 1) Začneme s náhodnými vahami pro jednotlivé spoje.
- 2) Vybereme vstupní vektor x ze sady tréninkových příkladů.
- 3) Jestliže y se nerovná $d(x)$ (tzn., že perceptron dává nekorektní odpověď), pozměníme všechny spoje w_i podle vztahu: $\Delta w_i = d(x)x_i$.
- 4) Vrátime se zpět ke kroku 2.

Celá procedura je velmi podobná Hebbovu učicímu pravidlu s tím rozdílem, že pokud síť odpoví tak, jak od ní bylo očekáváno, váhy jednotlivých neuronů se už nemění. Kromě toho musíme také pozměnit prahovou hodnotu (T) spojení w_0 , která vzniká mezi predikátovou jednotkou $x_0 = 1$ a

³⁰ A PROPOSAL FOR THE DARMOUTH SUMMER RESEARCH PROJECT ON ARTIFICIAL INTELLIGENCE. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>. [16.10.2008].

³¹ VOLNÁ, E. Neuronové sítě 1. Ostrava 2002 [online]. Dostupný na [www: http://www.ki.fpv.ukf.sk/materialy_public/Umela%20inteligencia/neuronovesite.pdf](http://www.ki.fpv.ukf.sk/materialy_public/Umela%20inteligencia/neuronovesite.pdf). [16.10.2008].

³² To znamená klasifikaci pouze do dvou tříd.

výstupním neuronem. Teď již máme učící pravidlo a prahovou hodnotu pozměníme pouze v případě, že perceptron neodpovídá správně.³³

Rosenblatt je také autorem publikace *Perceptions and the theory of brain mechanisms. Principles of Neurodynamics* (Vnímání a teorie mozkových mechanismů. Principy neurodynamiky), která byla vydána v roce 1960 a je jednou z prvních knih zabývajících se neurovýpočty. Se svými kolegy se také podílel na řadě dalších projektů, jeden z nich je popsán v následující podkapitole.

Mark I Perceptron

Charles Wightman a Franc Rosenblatt vytvořili na Cornellově univerzitě v letech 1957 a 1958 první úspěšný model neuropočítače, který sloužil k rozpoznávání znaků. Neuropočítače jsou specializovaná elektronická zařízení, která lze používat pro realizaci funkcí umělých neuronových sítí. Mark I Perceptron byl založen na Cullochově a Pittsově jednoduchém modelu neuronu a bylo ho možné používat v případech, kde jsou lineárně separabilní proměnné. V jednoduchosti máme určitou hranici pro impuls. Pokud suma proměnných a jejich vah dosáhne této hranice, je vyslán impuls ($x = 1$). Pokud této hranice nedosáhne, impuls vyslán není ($x = 0$). Tento vskutku jednoduchý model se zdál být velkým příslibem do budoucna, nicméně problémem byla nelinearita, na kterou upozornili roku 1969 Marvin Minsky a Seymour Pappert ve své knize *Perceptrons* (viz. kap. 3.5.). Tento neuropočítač dokázal nastavovat celkem 51 různých synaptických vah a 400 vstupů, přičemž váhy byly realizovány potenciometry ovládanými elektromotory.³⁴ Problémem bylo, že Mark I byl pouze dvouvrstvý perceptron a proto si se situací, kdy bylo potřeba lineárně separovat hodnoty, nedokázal poradit. Tento problém byl vyřešen až o 20 let později, kdy byl představen tzv. MLP (Multi-layer Perceptron).³⁵ Navíc Mark I byl v podstatě ještě spíše ukázkovým nástrojem neuropočítače než reálné využitelným přístrojem pro řešení složitých problémů.

3.3. Adaline

Roku 1960 přišel Bernard Widrow a jeho student ze Stanford University se svým analogovým neuropočítačem zvaným ADALINE (ADaptive LINEar NEuron). Již z názvu můžeme pochopit, že se jedná o síť, u které probíhá adaptivní chování a učení. Jedná se o iterativní proces, při kterém je síti předkládáno mnoho vstupů a požadované výstupy, pomocí nichž se učí a následně by měla být schopna s vysokou pravděpodobností rozpoznat i takové vstupy, které ji učitel nenaučil. Platí zde přímá úměrnost, tudíž čím více síť naučíme, tím pravděpodobněji bude schopna určit správně požadovaný výstup. Adaline je síť s jedním neuronem pracujícím v bipolárním režimu a kromě vstupů přijímá ještě jeden doplňkový signál, který je vždy roven 1. Samotný trénovací proces probíhá tak, že nejprve náhodně nastavíme počáteční hodnoty synaptických vah (nejlépe nízké). Dále potom zvolíme trénovací parametr η , na kterém hodně závisí celý učební proces. Pokud je zvolena příliš nízká hodnota parametru, bude při procesu učení docházet k velmi pomalé konvergenci. Na druhé straně, pokud zvolíme příliš vysokou hodnotu tohoto parametru, ke konvergenci vůbec nemusí dojít. Proto je

³³ Perceptron and Adaline Neural Network.

<http://www.learnartificialneuralnetworks.com/perceptronadaline.html>. [28.10.2008].

³⁴ NOVÁK, M. a kol.: *Umělé neuronové sítě. Teorie a aplikace*. 1. vydání. Praha 1998, C. H. Beck. 382 s. ISBN 80-7179-132-6. Str. 281.

³⁵ Artificial Neural Networks/History – Wikibooks, collection of open-content textbooks.

http://en.wikibooks.org/wiki/Artificial_Neural_Networks/History. [16.10.2008].

doporučováno volit hodnotu parametru $0,1 \leq n\eta \leq 1$, kde n je počet vstupů. Poté už probíhá trénování (učení) sítě podle algoritmu:

$$y = \sum_j^n x_j w_j + \delta,$$

kde x je vstupní vektor,

w je vektor váhy,

n je počet uzlů,

δ je konstanta (hodnota prahu) a

y je výstup.

Následně probíhá adaptace váhových a prahových hodnot podle těchto pravidel:

$$w_{j+1} = w_j + \eta(k - y)x_j,$$

$$\delta_{j+1} = \delta_j + \eta(k - y),$$


kde k je očekávaná (požadovaná) hodnota příslušného vzoru. Nakonec je porovnávána poslední změna hodnoty váhy s odchylkou přípustnou. Pokud je poslední změna menší než přípustná odchylka, je trénovací proces ukončen.

Jiným způsobem procesu učení je použití pravidla delta (angl. Delta Rule) nebo také LMS (Least Mean Square) učící procedury. Ve své podstatě jde o obdobu výše uvedeného pravidla, jelikož i v tomto případě je podstatou minimalizace odchylek (chyb) všech reálných výstupů s jejich požadovanou hodnotou. Výhodou pravidla delta je možnost seskupování určitých vzorů neboli skupinová adaptace (angl. Batch Updating), při které vypadá pravidlo delta takto (první vzorec používáme pro sítě s jedním neuronem, druhý pro sítě obsahující více než jeden neuron):

$$\Delta w_i = \eta(k - y)x_i,$$

$$\Delta w_{ij} = \eta(k_j - y_j)x_i.$$

Adaline je zobecněním dříve zmíněného učícího algoritmu perceptronu, kde může být výstupem prahová funkční hodnota 1 nebo -1. Tato síť používá také výstupy 1 nebo -1, ale používá je i pro další učení. O rok později přišli Widrow a Hoff s ADALINE 2 (ADaptive LINear Element), jehož podstatu zachycuje obrázek 6.



Obrázek 6 - Adaline 2

Na levé straně ADALINE 2 vidíme přepínatelný vstupní vzor (1, -1), dále pak jednotlivé váhy w , sumu tohoto procesu a poté, při vzniklé chybě, možnost návratu na vstup. Adaline i Adaline 2 měly ovšem omezenou funkcionalitu, což přivedlo autory na myšlenku vytvořit síť, která by se skládala z několika takových sítí vzájemně kooperujících.

Madaline

MADALINE (Multiple ADALINE) je vylepšená vícevrstvá verze Adaline 2. Pro její trénování byl vytvořen algoritmus MRI. Popis tohoto algoritmu je poměrně zdlouhavý a proto jej zde nebudu uvádět. Jednoduše jde ale v této struktuře o to, že pokud se v Madaline vyskytuje několik subsítí typu Adaline, jejichž funkce jsou lineární, výsledná transformační funkce může mít nelineární charakter.


Za zmínku ještě stojí, že pro konstrukci těchto neuropočítačů bylo používáno miniaturních elektrochemických buněk zvaných memistory. Bernard Widrow založil v 60. letech první společnost svého druhu, Memistor Corporation, která se v letech 1962 – 1965 zabývala výrobou a prodejem právě těchto analogových neuropočítačů, které pracovaly pouze s několika stovkami umělých neuronů, což je zlomek schopností neuropočítačů dnešních, nicméně v tehdejší době se jednalo o technologický vrchol. Widrow na svých přístrojích demonstroval, že neuronové sítě jsou principálně schopny se učit, ovšem samozřejmě v závislosti na počtu neuronů a jejich vzájemného propojení. Z tohoto pohledu měly ovšem v té době neuronové sítě značná omezení.

3.4. ART

Stephen Grossberg, který působí na Boston University, je jedním z nejvlivnějších vědců, co se týče neuronových sítí. Zavedl mnoho pojmů, které se používají dodnes, jako je například pojem samoorganizace, kterou později využil ke své práci finský profesor Teuvo Kohonen u svých samoorganizačních map (viz kap. 5.2.). Spolu se svojí ženou Gail Carpenterovou přišel roku 1964 s teorií ART (Adaptive Resonance Theory). ART je založena na tzv. přírůstkovém shlukování, kdy je schopna se sama učit, rozlišovat jednotlivé podněty, adaptivně nastavovat počet klasifikačních skupin a zařazovat je do paměti. Je reakcí na předchozí dopředné sítě, které byly v této oblasti značně nestabilní. Pro tyto architektury je typická vysoká úroveň kontroly, zpětné odezvy a nelinearity. Problémem zde byla podobnost vstupů, jelikož pokud vzdálenost nebyla dostatečná, síť vstupy mylně interpretuje jako například nějaké již existující a tím může vzniknout chyba na výstupu. ART sestává ze dvou subsystémů: pozornostního a orientačního. Pozornostní subsystém má na starosti stabilizaci učení. Oriační subsystém pracuje vlastně jako detektor chyb, jelikož kontroluje pozornostní

subsystém, když v něm nastane nějaká neshoda. Zpětnovazební spoje zde zabezpečují tzv. test pozornosti. Z této struktury systému vznikly 4 základní vlastnosti:

- 1) Adaptivní modulace pozornostní bdělosti - systém může adaptivně upravovat pozornostní bdělost používající prostředí jako učitele. Jestliže prostředí neschvaluje aktuální rozpoznání systému, změní tento parametr na bdělejší.
- 2) Přímý přístup do kategorie - již naučené vzorce jsou okamžitě k dispozici v dané kategorii.
- 3) Samoškálovací výpočetní jednotky - pozornostní subsystém je založen na kompetitivním učení, zdůrazňujícím vzorové rysy, potlačujícím šum.
- 4) Samoupravující paměťové vyhledávání - systém může prohledávat paměť paralelně a vyhledávací pořadí mění adaptivně.³⁶



Obrázek 7 - Jednoduchá síť ART³⁷

V síti ART postupujeme tak, že nejprve vybereme neuron s maximální aktivitou, který posléze ověříme následujícím testem:

$$\frac{\sum_{i=1}^N t_U x_i}{\sum_{i=1}^N x_i} > \rho,$$

kde ρ je dříve stanovená prahová hodnota.

³⁶ Adaptive Resonance Theory. <http://www.ifi.uzh.ch/~krafft/papers/2001/wayfinding/html/node97.html>. [16.10.2008].

³⁷ Adaptive Resonance Theory – Wikipedia, the free encyclopedia. http://en.wikipedia.org/wiki/Adaptive_resonance_theory. [11.11.2008].

Pokud nevyhovuje testu, opakujeme ho znovu, nyní již bez tohoto neuronu. Proces končí nalezením neuronu, který testu vyhovuje. Pokud test nesplní ani jeden neuron, je pro aktuální vstupní vzor vytvořen neuron nový.

V neuronových sítích tohoto typu máme určitou základnu znalostí. Sítě jsou schopny získávat znalosti nové a učit se tak, přičemž některé staré informace tímto učením mění nebo ztrácí. V síti ART je poprvé prezentována myšlenka samoorganizace a v jejím důsledku redukce ztráty či modifikace starších informací. Architektura ART 1 je variantou používanou pro binární vzory.

ART 2 patří mezi architektury, které dokáží kategorizovat libovolné posloupnosti analogových vstupních vzorů a je tedy modelem pro spojitě vzory nabývající reálných hodnot. Nejmladšími z architektur ART jsou ART 3 a ARTMAP, které již dokáží rozeznávat některé složitější vizuální vzory. Tyto architektury jsou na tuto práci příliš obsáhlé, cílem bylo popsat základní architekturu sítě ART.

3.5. Minského a Pappertova kritika

Roku 1969 přichází první velký otřes pro umělou inteligenci jako celek. Marvin Minsky a Seymour Pappert vydávají knihu *Perceptrons*, která poukazuje na některá omezení a nedostatky tehdejších umělých neuronových sítí. Za hlavní nedostatek považují autoři to, že jednovrstvý perceptron není schopný naučit se funkci XOR. To, že dvouvrstvá síť se třemi neurony tuto funkci zvládá, nebylo ještě v té době známo. Navíc autoři se k tomuto problému postavili značně nevědecky, jelikož ho uzavřeli tak, že ani vícevrstevná síť nebude schopna toto vyřešit. Umělá inteligence v té době značně zaostávala za svým očekáváním a tak bylo tvrzení vlivných vědců všeobecně přijato a výzkum na poli neuronových sítí byl po dlouhou dobu 13 let téměř zastaven.

4. Nenaplnění předpokladů (1969 – 1982)

V tomto období se umělá inteligence stejně jako neuronové sítě potýkají s největší krizí od svého vědeckého vzniku. Vědci si uvědomují, že cíle, které byly stanoveny roku 1956, nebude možné naplnit ani v delším časovém horizontu a tak mnoho z nich omezuje svůj čas strávený na projektech a finanční prostředky se začínají přesouvat do jiných sektorů. Po těchto 13 let jsou výsledky omezeny na separované úspěchy několika málo projektů. Nicméně některých úspěchů bylo dosaženo i v tomto období. Například v roce 1977 se konalo první mistrovství v počítačovém šachu.

4.1. Cognitron a Neocognitron

V době hluboké krize umělé inteligence přichází jeden z mála světlých projektů, Cognitron japonského badatele a profesora Kunihika Fukushima (Kansai University) z roku 1975, který byl stimulován poznáváním struktury vizuálního traktu mozku.

O 5 let později vylepšil Fukushima Cognitron a vznikl nový Neocognitron, který je dodnes jedním z nejsložitějších paradigmat neuronových sítí. Je to vícevrstevná hierarchická neuronová síť, která dokáže rozpoznávat a učit se určité vzory.³⁸ V Neocognitronu se střídají dvě zpravidla dvourozměrné vrstvy se dvěma typy neuronů, označme je S a C. Neurony S jsou složeny ze dvou dílčích neuronů s excitačními synapsemi a inhibičními vazbami,³⁹ které získávají informace o analyzovaných obrazcích. Neurony C mají zpravidla pouze excitační synapse a zabývají se odchylkami v rozmístění a poloze obrazců. Neurony typu C vyskytující se v nejvyšší vrstvě se starají o konečnou klasifikaci sítě.

Jak jsem zmínil již v předchozím odstavci, Neocognitron je jedna z nesložitějších neuronových sítí, které kdy byly vytvořeny. Síť typu Neocognitron, kterou představil profesor Fukushima poprvé v roce 1988, obsahovala 20 vrstev, v nichž se vyskytovalo 156 oblastí, přičemž každá oblast obsahovala od 1 do 441 neuronů. V konečném součtu se v síti nacházelo 50 732 neuronů a více než 14 milionů synaptických vah. Tato konkrétní síť slouží k rozpoznávání obrazců a ručně psaných číslic, a to i při vysokém procentu zkreslení.⁴⁰

³⁸ Neocognitron – Scholarpedia. <http://www.scholarpedia.org/article/Neocognitron>. [19.10.2008].

³⁹ Excitační synapse zvyšují hodnotu signálu a usnadňují tak vznik dalšího vzruchu, inhibiční se naopak snaží vzniku vzruchu zabránit.

⁴⁰ NOVÁK, M. a kol.: Umělé neuronové sítě. Teorie a aplikace. 1.vydání. Praha 1998, C. H. Beck. 382 s. ISBN 80-7179-132-6. Str. 219-220.

5. Rozmach a následný útlum (1982 – 1993)


Roku 1982 končí zatím nejhorší období neuronových sítí v rámci umělé inteligence a přichází hned několik velkých objevů, které jsou popsány níže. Významný podíl na tomto rozvoji mají nové poznatky o biologické funkci mozku, které umožnily vytvořit nové postupy na poli neuronových sítí. Vznikají termíny jako „energie neuronových sítí“, „simulace paměti“, „uchování informace v dynamickém systému“ a mnoho dalších. V této době se také konala významná japonsko-americká konference v Kjótu o kooperativně-kompetitivních neuronových sítích, kde byl představen japonský projekt počítačů V. generace. V roce 1985 bylo založeno každoroční setkání Neural Network for Computing pod záštitou American Institute of Physics a o dva roky později se konala první mezinárodní konference o neuronových sítích pořádaná Institute of Electrical and Electronics Engineer's (IEEE), na které se sešlo 1800 účastníků.

Až dvouvrstvé neuronové sítě dokázaly vyřešit letitý problém s nelineární separabilitou, jelikož jednovrstvý perceptron dokáže rozdělit prostor pouze na dva podprostory a jeho použití je tak značně omezené. Nicméně dvouvrstvá síť už dokáže vymezit v prostoru libovolný konvexní útvar a třívrstvá síť dokonce libovolné množství takových útvarů v prostoru. Vznik mnoha typů vícevrstevných umělých neuronových sítí umožnil tomuto oboru rozmach, o kterém pojednávám v této kapitole.

Na konci 90. let přichází lehký útlum oboru neuronových sítí. Toto krátké období následuje po několika prozatím nejpłodnějších letech v této oblasti. Je to způsobeno také rozdělením neuronových sítí do několika menších specializovaných podoborů. Problémovým obdobím ho lze nazvat také z toho důvodu, že největší investice jsou směřovány do vojenství (radarové a sonarové signály) a to ne vždy na obranu jednotlivých států. Roku 1989 se konala konference na téma „neuronové sítě“. Jejím hlavním tématem bylo použití sítí právě pro obranu. O rok později uvedlo Ministerstvo obrany USA ve svém výzkumném programu pro inovace v malém podnikání⁴¹ 16 témat, která se týkala neuronových sítí, z toho v 13 se uvažovalo o jejich použití.

⁴¹ Originální název programu zní: Small Business Innovation Research Program.

5.1. Hopfieldova síť



Obrázek 8 - Hopfieldova síť⁴²

V roce 1982 byla Johnem Hopfieldem z California Institute of Technology navržena tzv. Hopfieldova síť. Hopfield ve své podstatě poukázal na to, jak efektivních výpočetních schopností lze dosáhnout propojením jednotlivých neuronů. Je to jednovrstvý model, který se učí sám a kde je každý neuron propojen se všemi ostatními kromě sebe sama. Množství vstupů, neuronů i výstupů je totožné. Je typickým příkladem asociativní paměti. Z jednotlivých vah mezi neurony nám vzniká čtvercová symetrická matice, z čehož pramení schopnost této sítě vybavovat si vzory inverzní ke vzorům již naučeným. Váhy jsou na počátku nastaveny na nulovou hodnotu a jejich změny se provádějí pomocí Hebbova pravidla. Během učení se váhy uzpůsobí podle předkládaných vzorů a při následném předložení vstupu jsou porovnávány hodnoty mezi všemi dvojicemi neuronů a váhy jsou upravovány podle toho, zdali se liší od předkládaného vzoru. Pokud jsou tyto váhy stejné, zvyšuje se váha spoje o jednu jednotku a pokud ne, váha se o jednu jednotku snižuje. Na počátku učení jsou jednotlivé váhy a prahy určené podle následujících vztahů:⁴³

$$w_{ij} = \sum_{k=1}^m 2x_i^{(k)}x_j^{(k)} \quad \text{pro } i \neq j,$$

$$w_{ij} = 0 \quad \text{pro } i = j,$$

⁴² Hopfield Net – Neural Networks with Java. <http://www.nnwj.de/hopfield-net.html>. [19.10.2008].

⁴³ V tomto případě zvažuji sekvenční (asynchronní) Hopfieldův model pro případ bipolárních vzorů. Případně lze pracovat se sekvenčním modelem pro binární vzory. Je také možné použití paralelního (synchronního) Hopfieldova modelu pro případ binárních nebo bipolárních vzorů, kde je možná paralelní aktualizace stavů sítě. Více informací viz. Literatura a zdroje (kap. 8.).

$$\delta_i = \frac{1}{2} \sum_{j=1}^n w_{ij},$$

kde $x_{ki}x_{kj}$ jsou $i(j)$ -té prvky k -tého trénovacího vzoru nabývající hodnoty z množiny $\{-1, 1\}$,

w_{ij} jsou synaptické váhy a

δ_i je prahová hodnota i -tého prvku trénovacího vzoru.

Síť nejdříve předložíme stavový vektor $a(0)$, jehož hodnoty jsou nulové a posléze aktualizujeme jeho složky takto (první vzorec slouží pro výpočet aktivity, druhý až čtvrtý pak k samotné aktualizaci stavu):

$$u_i(k+1) = \sum_{j=1}^n w_{ij}x_j(k) + \delta_i,$$

$$x_i(k+1) = 0 \quad \text{pro } u_i(k+1) < 0,$$

$$x_i(k+1) = 1 \quad \text{pro } u_i(k+1) > 0,$$

$$x_i(k+1) = x_i(k) \quad \text{pro } u_i(k+1) = 0.$$

Takovýmto způsobem pokračujeme až do chvíle, kdy síť dospěje do stabilního stavu, což může znamenat například shodu dvou po sobě jdoucích iterací. Záleží pouze na zvoleném kritériu.⁴⁴

Hopfieldova síť je schopna se sama učit a také rozpoznávat jednotlivé vzory, jediným jejím problémem je nedostatečná paměť. Aby síť minimalizovala chybovost, nesmí počet vzorů převýšit 15% počtu neuronů v síti, což je poměrně zásadním omezením. Kladnou stránku zase lze vidět v její schopnosti určit správný výstup i v případě špatně zadaného vstupu. Tady se ale klady a zápory setkávají, jelikož čím máme podobnější vzory, tím pravděpodobnější je vznik chybového výstupu.⁴⁵

Hopfieldova síť se v současné době používá především pro řešení problému obchodního cestujícího. Máme určitý počet měst, které chce cestující navštívit, přičemž každé právě jednou a každý úsek nebo spoj mezi městy má určitou vzdálenost (váhu). Jedná se o typickou optimalizační úlohu, ve které nám Hopfieldova síť zjistí nejefektivnější trasu.

⁴⁴ NOVÁK, M. a kol.: Umělé neuronové sítě. Teorie a aplikace. 1.vydání. Praha 1998, C. H. Beck. 382 s. ISBN 80-7179-132-6. Str. 168-172.

⁴⁵ Hopfield Model. <http://www.comp.nus.edu.sg/~pris/AssociativeMemory/HopfieldModel.html>. [19.10.2008].

5.2. Kohonenova síť

Roku 1982 přišel finský profesor Teuvo Kohonen s tzv. samoorganizovanými mapami (angl. Self-organizing Map, SOM) neboli Kohonenovou sítí, která nepotřebuje k učení učitele, ale učí se sama. Podporou jí byly četné výzkumy mozkových funkcí, zejména pak zkoumání prostorové organizace mozkové kůry a také teorie o původu a funkci jednotlivých neuronů. Zjistilo se, že neuron při svém vzniku nemá ještě žádnou specializaci, je to tzv. „nepopsaný list“ a až v průběhu života se shlukuje na určitých místech v mozku, kde podporuje jednotlivé mozkové funkce. Odtud také výraz „samoorganizace“ (angl. Self-organization), jelikož každý neuron si sám organizuje svou cestu k určité specializaci.

Kohonenova síť má dvě vrstvy a vychází z původních neuronových sítí s asociativní pamětí a adaptivním způsobem učení. Počet vstupů se rovná dimenzi vstupního prostoru. Kohonenova myšlenka tkví v existenci dvou subsystémů s rozdílnými vlastnostmi, které na sebe vzájemně působí. Prvním z nich je kompetitivní neuronová síť, která používá tzv. „vítěz bere vše“ (angl. Winner Takes All) algoritmus.⁴⁶ Druhý subsystém pozměňuje synaptickou plasticitu neuronů v procesu učení a je na něj dohlíženo neuronovou sítí. Na počátku jsou váhy jednotlivých neuronů nastaveny náhodně. Proces učení je lokalizován do určité části, jelikož nám jde o vymezení co nejpřesnějších hranic.⁴⁷ Tento proces probíhá následovně. Sítí jsou předkládány vzory v náhodném pořadí a pro každý předložený vzor hledáme odpovídající nejbližší neuron. Jednotlivé váhy „vítězného“ neuronu a neuronů v jeho okolí jsou poté adaptovány. Tomuto „vítěznému“ neuronu je následně nastavena jeho hodnota na 1, zatímco hodnota ostatních je nulová. Vítězný neuron a jeho blízké okolí (angl. Block Part) si pak své váhy může přenastavit na nové hodnoty.

Kohonenova síť se, díky své vysoké kvalitě výstupu, používá například pro rozpoznávání znaků v nejmodernějších OCR softwarech.⁴⁸

5.3. Boltzmannův stroj

V roce 1983 přišli pánové Geoffrey E. Hinton z University of Toronto a Terry Sejnowski s tzv. Boltzmannovým strojem (angl. Boltzmann Machine), který je stochastickou variantou Hopfieldovy sítě, která používá při procesu učení metody tzv. simulovaného žihání. Základ těchto metod pochází již z roku 1953. Původně byly tyto modely používány pro simulaci biologických neuronů, avšak později se uplatnily i na poli umělých neuronových sítí. V podstatě jde o to, že v celé síti se vyskytuje určité množství lokálních minim a cílem sítě je z těchto minim získat heuristickými metodami minimum globální, což už je ovšem záležitost použitého algoritmu. Zpravidla není možné prohledat všechna místa v síti a tak k nejlepšímu výsledku vede algoritmus, který postupuje dostatečně systematicky při prohledávání sítě. V Boltzmannově stroji je obsažen prvek náhodnosti, neboli šum. Cílem tohoto šumu je zajistit lepší konvergenci sítě. Základní rozdíl od jiných sítí je v tom, že kromě několika viditelných neuronů se v této síti mohou vyskytovat i neurony skryté. Učící algoritmus, který tato síť používá, je uveden v jedné z kapitol publikace z roku 1983, na které se oba pánové podíleli.⁴⁹

⁴⁶ Ukázku tohoto algoritmu lze nalézt například na:

http://cobweb.ecn.purdue.edu/~zak/ee595c/funwork_3/ricky/neural.html

⁴⁷ Kohonen Network – Scholarpedia. http://www.scholarpedia.org/article/Kohonen_network. [29.10.2008].

⁴⁸ OCR (Optical Character Recognition) je metoda, která pomocí scanneru umožňuje digitalizaci tištěných textů, s nimiž pak lze pracovat jako s normálním počítačovým textem. OCR software je program, který používá tuto metodu.

⁴⁹ HINTON, G. E. and SEJNOWSKI, T. J.: Optimal Perceptual Inference. *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, Washington DC 1983, pp. 448-453. Dostupný na [www](http://papers.cnl.salk.edu/PDFs/Optimal%20Perceptual%20Inference%201983-646.pdf): <http://papers.cnl.salk.edu/PDFs/Optimal%20Perceptual%20Inference%201983-646.pdf>.

Je vhodný především pro použití v jednovrstvých sítích, nicméně ho lze efektivně použít i při složení několika jednovrstvých sítí do většího logického celku. Boltzmannův stroj lze aplikovat na dva druhy problémů, a to problém vyhledávací a problém učící, které na sebe ovšem vzájemně navazují. U vyhledávacího problému máme pevně dané váhy na jednotlivých spojkách. Pravděpodobnostní dynamika Boltzmannova stroje potom umožňuje binárním vektorům mít nízké funkční hodnoty. U problému učícího jsou pak sítí předloženy vektory obsahující binární data a od sítě se požaduje, aby se naučila generovat tyto vektory s co nejvyšší pravděpodobností. Aby bylo dosaženo kýženého výsledku, jsou prohledávány váhy jednotlivých spojení binárních vektorů, přičemž datové vektory mají nízké funkční hodnoty. Probíhá zde mnoho malých úprav, které vyžadují řešení velkého množství vyhledávacích problémů.⁵⁰

Boltzmannovo učení

O dva roky později, v roce 1985, vytvořili Ackley, Hinton a Sejnowski učící algoritmus, který nazvali Boltzmannovo učení, o němž se lze dozvědět více v jedné ze mnou uváděných publikací.⁵¹

5.4. Backpropagation

Již v roce 1974 popsal tento algoritmus (metodu) Paul Werbos, ale až roku 1986 David E. Rumelhart spolu s Geoffrey E. Hintonem a Ronaldem J. Williamsem vydali knihu *Learning Internal Representation by Error Propagation* a v ní obsažený algoritmus nazvaný backpropagation (back-propagation) nebo také error propagation. Tento algoritmus je také známý pod názvem „metoda zpětného šíření“ nebo „zobecněné pravidlo delta“ (angl. Generalized Delta Rule) a je používán pro učení vícevrstevných perceptronových sítí.

Jedná se o metodu, která se učí s učitelem. Algoritmus je vhodný především pro dopředné sítě neboli sítě s dopředným šířením signálu (angl. Feed-forward Networks) bez propojení neuronů v rámci jedné vrstvy, nicméně je možné ho použít v podstatě na libovolnou neuronovou síť. Backpropagation je gradientní metodou, jejíž podstatou je minimalizace součtu čtverců chyby výstupů. Proces učení sítí používajících tuto metodu vypadá následovně. Síť je nejprve prezentován určitý vzor a dochází k dopřednému šíření signálu. Poté nastupuje zpětné šíření analýzy odpovídajících chyb a nakonec jsou adaptovány vhodné parametry sítě.⁵² Podrobnějším popisem algoritmu backpropagation se zde nebudu zabývat. Je podrobně rozebrán například v jednom z dílů největšího českého sborníku umělé inteligence.⁵³

⁵⁰ Boltzmann Machine – Scholarpedia. http://www.scholarpedia.org/article/Boltzmann_machine. [1.11.2008].

⁵¹ MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: *Umělá inteligence (Díl 4)*. 1.vydání. Praha 2003, Academia. 475 s. ISBN 80-200-1044-0. Str. 219-220.

⁵² NOVÁK, M. a kol.: *Umělé neuronové sítě. Teorie a aplikace*. 1.vydání. Praha 1998, C. H. Beck. 382 s. ISBN 80-7179-132-6. Str. 191.

⁵³ MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: *Umělá inteligence (Díl 4)*. 1.vydání. Praha 2003, Academia. 475 s. ISBN 80-200-1044-0. Str. 209-210.

5.5. NETtalk

V roce 1987 přišli Terrence J. Sejnowski z Johns Hopkins University a Charles R. Rosenberg z Princeton University se systémem NETtalk, jehož cílem je přeměnit anglicky psaný text do mluvené podoby. Cílem bylo vytvořit takový systém, který dokáže s co největší přesností napodobit lidskou řeč. Sami autoři tvrdí, že: „NETtalk je historicky prvním významným použitím neuronových sítí.“⁵⁴ Trochu odvážné tvrzení po 31 letech existence vědy, do které se investovalo nepředstavitelné množství finančních prostředků.

NETtalk se učí tréninkem a sdílením jednotlivých jednotek mezi sebou, přičemž platí, že čím více slov se program naučí, tím lepší výkonnost předvádí při zobecňování a výslovnosti slov. Pokud dojde k nějakému poškození, systém je schopný se velice rychle vrátit do původního znalostního stavu, ačkoliv samotný proces učení se je poměrně zdoluhavý. Autoři ovšem upozorňují, že časový úsek, za který se naučí mluvit a správně vyslovovat člověk, je nesrovnatelně delší. Navíc angličtina není zrovna jednoduchým jazykem právě co se týče výslovnosti, jelikož obsahuje mnoho výjimek a výslovnost je značně závislá na ostatních písmenech.⁵⁵

Jak vlastně NETtalk funguje v praxi? NETtalk používá metodu pohyblivého okénka a na vstupní vrstvu přivede vždy 7 znaků textu. To je důležité právě kvůli anglické výslovnosti, jelikož tím postihne de facto všechny výjimky. Má vstupní vrstvu, která obsahuje 7 x 9 znaků z 29 možných, jednu skrytou vrstvu obsahující 80 neuronů a vrstvu výstupní, která má 26 neuronů a interaguje s učitelem. Díky té se síť učí správnou výslovnost. NETtalk byl naučen na 1024 slovech a po deseti trénovacích kolech bylo možno slyšet poměrně srozumitelnou řeč. Po padesáti kolech vykazovala tato trénovací množina již 95% úspěšnost. Důležitější ale je, že tento systém po naučení dokázal vyslovovat nenaučená slova s úspěšností 78%. Představme si člověka, který zná pouze 1024 slov a i přesto dokáže v podstatě jakékoliv jemu neznámé slovo vyslovit s tak vysokou pravděpodobností správnosti. V tom se NETtalk odlišuje například od komerčně používaného DEC-talku, který je založen na ručně zadaných gramatických pravidlech. Pokud ho slyšíme „mluvit“, výstup je kvalitnější, nicméně úsilí do něj vloženo bylo několikanásobně vyšší.

Příklad adaptace systému NETtalk: Ve vstupní vrstvě máme těchto 7 znaků: _ a _ c o w _ . Ty projdou skrytou vrstvou k vrstvě výstupní, kde učitel síti řekne, že *c* se v tomto kontextu vyslovuje jako *k*. Poměrně jednoduchý princip, který ovšem v závislosti na počtu trénovacích kol vykazuje vynikající výsledky.

⁵⁴ MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence (Díl 1). 1.vyd. Praha, Academia 1993. 264 s. ISBN 80-200-0496-3. Str. 224.

⁵⁵ ParallelNetsPronounce-TJSejnowski.pdf.
<http://www.cnl.salk.edu/ParallelNetsPronounce/ParallelNetsPronounce-TJSejnowski.pdf>. [21.10.2008].

6. Současnost (1994 - 2008)

Jak jsem naznačoval již v předchozí kapitole, neuronové sítě se v posledních několika letech začínají specializovat na určité oblasti. Navíc nových aplikací je takové množství, že je nelze shrnout do kratší kapitoly. Spíše by pomohla publikace zabývající se pouze kratším úsekem současných produktů oboru neuronových sítí. Nicméně jsem do této kapitoly zařadil alespoň jeden algoritmus, který je pro současnost neuronových sítí velmi podstatný a jehož podrobnější popis jsem v české literatuře nenašel. Druhá část kapitoly je věnována počítači Deep Blue firmy IBM, který naplnil, ačkoliv o 27 let později, první očekávání Darmouthské konference.

6.1. Lavenbergův – Marquardtův učící algoritmus

Lavenbergův – Marquardtův učící algoritmus byl publikován v roce 1994 a je rychlejší a efektivnější než jeho předchůdce backpropagation. Využívá se u vícevrstevných perceptronových sítí a používá nelineární metodu nejmenších čtverců. Pro účely neuronových sítí zde používáme chybovou funkci:

$$e = \sum_{k=1}^P \frac{1}{2} (t_k - y_k)^2,$$

kde t je žádaný výstup,

y je skutečný výstup a

P je celkové množství použitých trénovacích vzorů.

Při učení sítě za pomoci tohoto algoritmu musíme aplikovat následujících 5 kroků:

- 1) Prezentovat síti všechny vstupy a vypočíst příslušné výstupy a chyby. Vypočíst střední čtvercovou chybu podle vzorce uvedeného výše.
- 2) Vypočíst matici, tzv. Jakobián $J(z)$, kde z reprezentuje váhy a šikmost (angl. Biases) sítě.
- 3) Vypočíst novou Lavenbergovu – Marquardtovu váženou rovnici, abychom získali Δz .
- 4) Znovu spočítat chybu použitím $z + \Delta z$. Pokud je tato chyba menší než ta v kroku 1, omezíme tréninkový parametr μ parametrem μ^- , nechť $z = z + \Delta z$ a zpět ke kroku 1. Jestliže se chyba nesnížila, potom zvýšíme parametr μ parametrem μ^+ a vrátíme se zpět ke kroku 3. Parametry μ^- a μ^+ jsou definovány uživatelem.
- 5) Předpokládá se, že algoritmus dokonvergoval, když je úroveň gradientu (angl. Norm of Gradient) menší než nějaká předurčená hodnota, nebo když je chyba snížena na určitou akceptovatelnou hodnotu.

Aktuální vážený vektor Δz se spočítá takto:

$$\Delta z = [J^T(z)J(z) + \mu I]^{-1} J^T(z)E$$

kde E je vektor velikosti P , který se spočítá takto:

$$E = [t_1 - y_1, t_2 - y_2, \dots, t_P - y_P]^T$$

Tady se $J^T(z)J(z)$ nazývá Hessiánskou maticí, kde I je jednotková matice a μ je učicí parametr. Pokud je tento parametr nulový, hovoříme o Gauss-Newtonově metodě. Při příliš vysoké hodnotě parametru dochází k nejstrmějšímu sestupu nebo k chybě algoritmu zpětného chodu. K zajištění konvergence je parametr μ automaticky přizpůsobený při každé iteraci, přičemž je potřeba při každé iteraci znovu spočítat Jakobián a inverzi čtvercové matice $J^T(z)J(z)$.⁵⁶

6.2. Deep Blue

3. května 1997 v New Yorku došlo k jedné z největších světových událostí na poli umělé inteligence. Počítač Deep Blue sestrojený firmou IBM dokázal porazit šachového velmistra Gari Kasparova. V souboji hraném na 6 partií zvítězil poměrem jedné partie 3,5:2,5. Odměnou pro vítěze byla částka 700 000 dolarů, které výzkumný tým vložil do dalšího výzkumu. Pro vývoj celého utkání byla klíčová druhá partie, kterou Deep Blue vyrovnal skóre na 1:1. Podle mnoha názorů při ní totiž počítač prošel Turingovým testem a prokázal tak vlastní inteligenci, kdy odmítl nastraženou materialistickou léčku, kterou by prý byla schopna prohlédnout jen hrstka šachových velmistrů a volil jiný tah, díky kterému nakonec zvítězil.

Šachy celkově byly již dlouhou dobu předmětem výzkumu na poli umělých neuronových sítí, protože se jedná o jednoznačně myšlenkovou záležitost. Hráč musí promýšlet několik tahů dopředu, přičemž nemá takovou paměťovou kapacitu jako počítač. Z tohoto hlediska by se dalo říci, že takového šachového velmistra porazí počítač bez velké námahy, jak již bylo předneseno na Darmouth College v roce 1956. Ukázalo se ale, že „hrubá síla“ počítače, který sice má v paměti ohromné množství pozic (u Deep Blue konkrétně 200 milionů za sekundu), není postačující. Zásadní roli zde hrají zkušenosti, protože i s takovouto pamětí dokáže počítač kalkulovat „pouze“ 7 tahů dopředu (v limitu 3 minuty na tah), což zhruba dokáže i Kasparov a tudíž se takto vyrovnaný boj předpokládal. Problém šachového počítače tkví v tom, že je tato hra velmi komplexní, nezáleží v ní pouze na počtu sebraných figurek, pouze na postavení na šachovnici, ale na mnoha vzájemně propojených proměnných, které se velmi těžko aplikují do nějakého programu.

Nicméně tímto utkáním rozhodně nebyla prolomena bariéra mezi člověkem a strojem. Tento okamžik přijde až ve chvíli, kdy žádný šachista nedokáže vzdorovat počítačové simulaci této hry.⁵⁷

⁵⁶ V09N02P2-41-51.pdf. <http://bsrc.kaist.ac.kr/nip-lr/V09N02/V09N02P2-41-51.pdf>. [21.10.2008].

⁵⁷ Kasparov vs. DeepBlue. <http://www.gacr.cz/~michal/clanky/kasparov.html>. [21.10.2008].

7. Budoucnost neuronových sítí

V této kapitole se budu zabírat budoucností neuronových sítí. Nejde mi o přesný popis toho, čeho toto odvětví v budoucnosti dosáhne. Bylo by to svým způsobem pouze odhadování, k jakému dochází již od vzniku této disciplíny. V podstatě nikdy nebylo předpokládaných predikcí dosaženo. Zaměřím se zde na 3 hlavní oblasti problémů, k jejichž řešení se dnes již neuronové sítě čas od času používají, ale v budoucnosti očekávám jejich širší aplikační využití. Jsou to problémy klasifikace, predikce a rozpoznávání.

7.1. Klasifikace

Klasifikace je přiřazení podobných jevů do společné třídy; v objektově orientovaném systému soustava stejnorodých skupin nebo tříd objektů reálného světa, které vykazují podobnou strukturu a obdobnou sadu metod.⁵⁸

Z výše uvedené definice nemusí být jasný praktický význam a proto se trochu oprostíme od teorie. Klasifikace je činnost, kterou lidský mozek provádí každý den, neustále něco klasifikujeme. Ať už je to vhodnost oblečení, nákup v obchodním domě nebo výběr partnera. Jednoduše nám do hlavy přicházejí vstupy (proměnné), kterých může být velké množství, přičemž platí přímá úměrnost. Čím více je vstupů, tím těžší a složitější rozhodování. Člověk je tvor chybný a proto často některé proměnné považuje za nepodstatné a vypouští je, čímž se může dopustit chyby.

Velikou výhodou neuronových sítí je to, že problém klasifikace řeší velmi dobře i při velkém množství proměnných. Vezmeme-li v úvahu pouze binární kódování, potom například při třech vstupech máme 8 možností řešení, při šesti už 64 a při deseti dokonce 1024 a to je potřeba podotknout, že ve složitějších problémech se nachází proměnných i několikanásobně více. Navíc když není problém pouze binární, ale máme například 10 možností z každého vstupu, problém se dostává do člověkem nezvládnutelné situace (při pěti vstupech 100 000 možností). Pokud je neuronová síť dobře naučena, zvládne i takto složité situace bez chyby. Navíc je schopna pomocí neurální citlivostní analýzy⁵⁹ vypustit některé proměnné a usnadnit si tak rychlost výpočtu.

Praktická využitelnost neuronových sítí při klasifikaci prochází napříč celým oborem umělé inteligence, v současné době nejvíce oblastí robotiky. Mnoho robotů má již zabudovány mechanismy, které používají algoritmy neuronových sítí pro vyhodnocení situace, ve které se nacházejí. Také disponují funkcemi, které zajišťují jejich následné operace. Největší krok na této cestě udělalo zatím Japonsko, kde již existují plně robotizované továrny používající (zatím) poměrně jednoduché neuronové sítě pro orientaci svých „zaměstnanců“. Klasifikaci lze použít i ve zdravotnictví, například u EKG a jeho významu při srdeční arytmií. V budoucnosti bychom se mohli dočkat mnohem sofistikovanějších přístrojů, které by mohly používat složitější neuronové sítě a možná i něco, co lze nazvat umělým mozem.

⁵⁸ Slovník VÚGTK – klasifikace. http://www.vugtk.cz/slovník/1125_klasifikace. [31.10.2008].

⁵⁹ Tato analýza slouží k určení nejvýznamnějších proměnných v modelu a pomáhá tak dosáhnout nejlepšího možného řešení.

7.2. Predikce

Predikcí neboli předpovědí (odhadem) budoucího chování určitého systému se zabývá mnoho jiných věd, jako je třeba fyzika, matematika nebo statistika. Potřeba predikce postihuje mnoho různých oblastí, například předpověď počasí, budoucí průběh globálního oteplování, vývoj akcí na světových burzách a mnoho dalších. Výhodou neuronových sítí je to, že ke své předpovědi nepotřebují úplný výčet chování predikovaného systému, a i přesto dokáží poskytnout poměrně relevantní výsledky.⁶⁰ Oproti výše zmíněným vědám totiž nepotřebují ke své funkci model a proto jsou více odolné proti velkému kolísání a náhodným šumům. Neuronové sítě zpracovávají historická data a podle nich předpovídají budoucí vývoj pomocí tréninku tak, že jsou vždy vzaty dva vektory (vstupní a výstupní) a následně posunuty o tolik časových jednotek, o kolik si přejeme predikovat. Toto je samozřejmě pouze základ, poté vstupuje do sítě několik proměnných a situace se začíná komplikovat. Opět zde platí přímá úměrnost, takže čím více dat na učení síti poskytneme, tím kvalitnější výstup nám dá a navíc bude schopna se sama učit a tím se zdokonalovat. V podstatě lze říci, že čím chaotičtější systém máme, tím spíše lze nasadit neuronové sítě, ačkoliv ani ty nemusí v extrémních případech stačit.

7.3. Rozpoznávání

Rozpoznávání je oblastí, ve které se dnes neuronové sítě již hojně používají. Nejjednodušší sítě začínaly s rozpoznáváním různých jednoduchých geometrických tvarů, později se začalo s rozpoznáváním písmen a vůbec psaného textu, což je dnes v podstatě standardní výbavou scannerů. Průlomem v této oblasti byl Fukushimaův Cognitron a Neocognitron. Dalším velmi úspěšným dílem byla LeCunova síť pro rozpoznávání ručně psaného textu z roku 1989. Konkrétně uměla tato síť sama rozpoznávat směrovací čísla na dopisech a používala k tomu metodu zpětného šíření. Co se týče právě rozpoznávání textu, pracuje se dnes už jen na jeho zdokonalování a na převodu textu psaného rukou do počítačové formy. Nutno říci, že s tímto problémem by si často nevěděl rady ani člověk, jelikož písmo každého člověka je specifické a tudíž velmi špatně definovatelné. Nebo problém převodu starých tištěných textů, které mají vysoké procento zašumění, do počítačové podoby. Stejně jako u predikce se ale neuronové sítě jeví jako nejlepší řešení, jelikož vždy poskytnou nějaký výstup a zpravidla i velmi kvalitní.

Poměrně novou oblastí je převod tištěného textu do hlasového výstupu, jež se používá pro předčítání publikací nevidomým či jinak zrakově postiženým, anebo reakce počítače na hlasový požadavek uživatele. Tento problém je opět jako stvořený pro neuronové sítě díky své neurčitosti a analogii s fungováním lidského mozku. Předpovědi na tomto poli jsou ohromné, hlasové ovládání počítače s mnoha různými doplňky pro pohodlí a zabezpečení nejsou výjimkou. Cíle jsou samozřejmě důležité, ale o mnoho důležitější bude praktická realizace a zavedení do života člověka.

⁶⁰ Opět za předpokladu, že je síť dobře naučena.

Závěr

Na závěr bych rád zhodnotil výsledky této práce. Cílem bylo zmapování historického vývoje neuronových sítí způsobem, který jsem v žádné literatuře nenalezl, způsobem skutečného průvodce historií tohoto oboru. Nakonec mohu říci, že rozdělení do pěti historicky významných období bylo rozumné a dodává práci na přehlednosti. Mojí snahou bylo vytvořit text, kterému porozumí i čtenář zkoumající neuronové sítě poprvé, ačkoliv dobrý matematický základ je potřeba. Zároveň by tato práce měla poskytnout zajímavé informace i lidem, kteří se oboru neuronových sítí věnují déle. Fundamentálním smyslem práce nebylo popsání všech neuronových sítí vytvořených za dobu existence tohoto oboru, ale spíše ukázat cestu, kterou tato disciplína procházela a jakým způsobem se stala populární. Myslím, že tento cíl práce splnila. Do práce jsem zahrnul informace jak o sítích, tak o algoritmech na ně aplikovatelných. V neposlední řadě poukazuji na oblast využitelnosti, která je v konečném důsledku tím nejdůležitějším.

V průběhu studia dané problematiky mě zaujaly dvě aplikační oblasti, kterým bych se v budoucnu rád věnoval. První z nich jsou počítačové šachy, o kterých jsem se zde také zmínil a dokonce jim věnoval dvě podkapitoly. Druhou oblastí je kooperace robotiky a neuronových sítí a snaha o vytvoření tzv. „umělého mozku“, což souvisí i s mými zájmy mimo obor informatiky.

Byl bych rád, kdyby v budoucnu vznikly některé publikace, které by se určitými částmi neuronových sítí zabíraly podrobněji než tato práce. Jak už jsem zmínil výše, tato oblast se nejprve stala poměrně specializovanou částí umělé inteligence a v posledních letech se sama rozděluje na několik podoblastí. Touto prací lze získat poměrně dobrý teoretický náhled na celou problematiku, k vyřešení konkrétních problémů bych ovšem zvolil práci specializovanější na konkrétní část neuronových sítí. Tím bych rád povzbudil některé čtenáře, které neuronové sítě zajímají a rádi by jim věnovali svůj čas při psaní své závěrečné vysokoškolské práce.

Literatura a zdroje

Literatura je řazena podle abecedního pořadí jmen autorů. V sekci „Internetové zdroje“ jsou uvedeny nejprve dokumenty ve formátu pdf, poté dokumenty v ostatních formátech (htm, html, php). U internetových zdrojů je uveden název domovské stránky, jelikož konkrétní odkazy jsou přístupny v poznámkách pod čarou v textu. Jediný případ, kdy není uvedena domovská stránka, je odkaz na externí dokument. Za této situace odkazují i v závěrečném přehledu na konkrétní stránku.

Literatura

JIRKŮ, P., VEJNAROVÁ, J.: Formální logika – Neformální výklad základů formální logiky. 2.vydání. Praha 2005, Oeconomica. 161 s. ISBN 80-245-0974-1.

KULIŠŤÁK, P.: Neuropsychologie. 1.vydání. Praha 2003, Portál. 327 s. ISBN 80-7178-554-7.

LEM, S.: Tajemství čínského pokoje. Mladá fronta 1999. Edice Kolumbus. 200 s. ISBN 80-204-0826-6. Str. 92-93.

MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence (Díl 1). 1.vydání. Praha 1993, Academia. 264 s. ISBN 80-200-0496-3.

MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence (Díl 3). 1.vydání. Praha 2001, Academia. 328 s. ISBN 80-200-0472-6.

MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence (Díl 4). 1.vydání. Praha 2003, Academia. 475 s. ISBN 80-200-1044-0.

NOVÁK, M. a kol.: Umělé neuronové sítě. Teorie a aplikace. 1.vydání. Praha 1998, C. H. Beck. 382 s. ISBN 80-7179-132-6.

SEARLE, J. R.: Minds, Brains and Science. Harvard University Press 1984. 112 pp. ISBN 0-674-57631-4.

ZELINKA, I.: Umělá inteligence. Hrozba nebo naděje? Praha 2003, BEN – technická literatura. 144 s. ISBN 80-7300-068-7.

Internetové zdroje

HINTON, G. E. and SEJNOWSKI, T. J.: Optimal Perceptual Inference. *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, Washington DC 1983, pp. 448-453.

Dostupný na www: <http://papers.cnl.salk.edu/PDFs/Optimal%20Perceptual%20Inference%201983-646.pdf>.

VOLNÁ, E. Neuronové sítě 1. Ostrava 2002 [online]. Dostupný na www:

http://www.ki.fpv.ukf.sk/materialy_public/Umela%20inteligencia/neuronovesite.pdf.

<http://bsrc.kaist.ac.kr/nip-lr/V09N02/V09N02P2-41-51.pdf>

<http://www.cnl.salk.edu/ParallelNetsPronounce/ParallelNetsPronounce-TJSejnowski.pdf>

http://cobweb.ecn.purdue.edu/~zak/ee595c/funwork_3/ricky/neural.html

<http://cse.stanford.edu/class/sophomore-college/projects-00/neural-networks/index.html>

<http://ei.cs.vt.edu/~history/Perceptrons.Estebon.html>

http://en.wikibooks.org/wiki/Main_Page

http://en.wikipedia.org/wiki/Main_Page

<http://www.comp.nus.edu.sg/~pris/AssociativeMemory/HopfieldModel.html>

<https://www.dacs.dtic.mil/techs/neural/neural4.php>

<http://www.ece.utep.edu/research/webfuzzy/docs/kk-thesis/kk-thesis-html/node12.html>

<http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>

<http://www.gacr.cz/~michal/clanky/kasparov.html>

<http://www.ibm.com/us/en>

<http://www.ifi.uzh.ch/~krafft/papers/2001/wayfinding/html/node97.html>

<http://www.learnartificialneuralnetworks.com>

http://www.livinginternet.com/i/ii_ai.htm

<http://www.nnwj.de>

<http://www.psych.utoronto.ca/users/reingold/courses/ai/turing.html>

http://www.scholarpedia.org/article/Main_Page

<http://www.vugtk.cz/slovník/index.php>

<http://www.youtube.com>