

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH
PEDAGOGICKÁ FAKULTA
KATEDRA FYZIKY

Bakalářská práce

Autor: Zdeněk Rokůsek

Vedoucí práce: Mgr. Petr Bartoš

2007

**Teoretické základy neuronových
sítí**

**The Theoretical Background
of Neuronal Networks**

Prohlášení:

Prohlašuji, že jsem tuto práci vypracoval samostatně a že jsem všechny použité zdroje uvedl v Seznamu použité literatury na konci této práce. Zároveň povoluji Katedře fyziky PF JU v Č. Budějovicích libovolné využití této práce.

V Českých Budějovicích dne 26. března 2007 _____

Obsah

ÚVOD	6
1. HISTORIE	7
1.1. 40. – 50. léta.....	8
1.2. 50. – 60. léta.....	8
1.3. 80. léta.....	9
2. BIOLOGICKÝ NEURON A NEURONOVÁ SÍŤ	11
2.1. Biologický neuron.....	11
2.1.1. <i>Tělo neuronu</i>	12
2.1.2. <i>Axon</i>	12
2.1.3. <i>Dendrity</i>	13
2.2. Biologická neuronová síť.....	13
3. MATEMATICKÝ MODEL NEURONOVÉ SÍŤE.....	15
3.1. Formální neuron.....	15
3.2. Matematický model neuronové sítě.....	16
3.2.1. <i>Organizační dynamika</i>	17
3.2.2. <i>Aktivní dynamika</i>	20
3.2.3. <i>Adaptivní dynamika</i>	20
4. APLIKACE NEURONOVÝCH SÍŤÍ.....	22
4.1. Využití neuronových sítí.....	22
4.2. Neuropočítač a PC.....	24
4.3. Použití neuronových sítí pro kompresi dat.....	25
4.3.1. <i>Základní pojmy</i>	25
4.3.2. <i>Kompresa a neuronové sítě</i>	26
5. KLASICKÉ MODEL Y NEURONOVÝCH SÍŤÍ.....	29
5.1. Síť perceptronů.....	29
5.2. Vícevrstvá síť.....	31

5.3. MADALINE.....	32
5.4. Síť s kaskádovou architekturou.....	32
6. ASOCIATIVNÍ NEURONOVÉ SÍTĚ.....	35
6.1. Lineární asociativní síť.....	35
6.2. Hopfieldova síť.....	36
6.2.1. <i>Základní model</i>	37
6.2.2. <i>Energetická funkce</i>	38
6.2.3. <i>Příklad aplikace Hopfieldovy sítě</i>	40
ZÁVĚR.....	41
ANOTACE.....	43
SEZNAM POUŽITÉ LITERATURY.....	44

Úvod

V posledních deseti letech opět vzrostl zájem o tzv. (umělé) neuronové sítě, což jsou velmi zjednodušeně řečeno matematické modely nervových systémů živých organismů. Jeden směr výzkumu v této oblasti se snaží pochopit a modelovat to, jakým způsobem myslíme a jak funguje náš mozek. Na druhé straně tohoto úsilí stojí inženýři, kteří, inspirováni neurofyziologickými poznatky, tyto modely neuronových sítí modifikují, popř. hardwarově realizují, aby je mohli využít pro řešení úloh z umělé inteligence.

Tato práce se snaží poskytnout základní fakta o tématice neuronových sítí. Poskytuje stručný přehled historie bádání v oblasti neurovýpočtů a objasňuje neurofyziologické motivace, které vedly k matematickému modelu neuronu a neuronové sítě. První výzkumy v tomto směru byly provedeny ve čtyřicátých letech minulého století a do dnešní doby už toto téma stihlo zažít svůj boom, stagnaci i renesanci. Biologie nám o mozku a jeho vnitřních pochodech, o neuronech a jejich vzájemné interakci přináší stále nové poznatky, které jsou tím hlavním základem, ze kterého při formulaci modelu neuronu vycházíme. Modelů neuronu je však možno vytvořit velké množství. Při tvorbě konkrétního modelu je pro jeho tvůrce zásadní otázkou účel daného modelu, jeho požadovaná podrobnost a způsob jeho realizace, ať už se jedná o implementaci v některém programovacím jazyku, formální matematický model či hardwarový model.

Neuron je elementární jednotka pro zpracování informace, podobně jako hradlo v integrovaných obvodech. Neuronová síť jsou propojené neurony. Neuronové sítě se osvědčily v těch nejsložitějších biologických systémech určených k přežití v jejich řízení. Neuronové sítě jsou obecně vzato „zařízení“, do kterých se pouští data a na výstupu/ech vycházejí data zpracovaná, nějakým způsobem závislá na datech vstupních.

1. Historie

1.1. 40-50 léta

Jako první práce v oboru neuronových sítí je považována studie Warrena McCullocha a Waltera Pittse z roku 1943 [5]. Ukázali, že nejjednodušší typy neuronových sítí mohou v principu počítat libovolnou aritmetickou nebo logickou funkci. Ačkoliv nepočítali s možností bezprostředního praktického využití svého modelu, jejich článek měl velký vliv na ostatní badatele.

V roce 1949 napsal Donald Hebb knihu *The Organization of Behavior*, [6] ve které navrhl učící pravidlo pro synapse neuronů. Toto pravidlo bylo inspirováno myšlenkou, že podmíněné reflexy, které jsou pozorovatelné u všech živočichů, jsou již vlastností jednotlivých neuronů. Hebb se tak snažil vysvětlit některé experimentální výsledky z psychologie.

Avšak 40. a 50. léta zatím ještě nepřinesla zásadní pokrok v oblasti neurovýpočtů. Typickým příkladem výzkumu z tohoto období byla v roce 1951 konstrukce prvního neuropočítače Snark, u jehož zrodu stál Marvin Minsky. Snark byl sice úspěšný z technického hlediska, ale ve skutečnosti nebyl nikdy využit k řešení nějakého zajímavého praktického problému. Nicméně jeho architektura později inspirovala další konstruktéry neuropočítačů.

V roce 1957 Frank Rosenblatt vynalezl tzv. perceptron, který je zobecněním McCullochova a Pittsova modelu neuronu pro reálný číselný obor parametrů. Pro tento model navrhl učící algoritmus, o kterém matematicky dokázal, že pro daná tréninková data nalezne po konečném počtu kroků odpovídající váhový vektor parametrů (pokud existuje) nezávisle na jeho počátečním nastavení. Tento výsledek vzbudil velké nadšení. Rosenblatt také napsal jednu z prvních knih o neurovýpočtech *Principles of Neurodynamics*.

Na základě tohoto výzkumu Rosenblatt spolu s Charlesem Wightmanem a dalšími sestrojili během let 1957 a 1958 první úspěšný neuropočítač, který nesl jméno Mark I Perceptron. Protože původním odborným zájmem Rosenblatta bylo rozpoznávání obrazců, Mark I Perceptron byl navržen pro rozpoznávání znaků. Znak byl promítán na světelnou tabuli, ze které byl snímán polem 20 x 20 fotovodičů. Intenzita 400 obrazových bodů byla vstupem do neuronové sítě

perceptronů, jejímž úkolem bylo klasifikovat, o jaký znak se jedná (např. „A“, „B“ apod.).

Mark I Perceptron měl 512 adaptovatelných váhových parametrů, které byly realizovány polem 8x8x8 potenciometrů. [7] Hodnota odporu u každého potenciometru, která právě odpovídala příslušné váze, byla nastavována automaticky samostatným motorem. Ten byl řízen analogovým obvodem, který implementoval perceptronový učící algoritmus. Jednotlivé perceptrony bylo možné spojit se vstupy libovolným způsobem. Typicky bylo použito náhodné zapojení, aby se ilustrovala schopnost perceptronů učit se požadované vzory bez přesného zapojení drátů v protikladu ke klasickým programovatelným počítačům.

Díky úspěšné prezentaci uvedeného neuropočítače se neurovýpočty, které byly alternativou ke klasickým výpočtům realizovaným na von neumannovské architektuře počítače, staly novým předmětem výzkumu. Frank Rosenblatt je proto dodnes některými odborníky považován za zakladatele tohoto nového oboru.

Krátce po objevu perceptronů Bernard Widrow se svými studenty vyvinul další typ neuronového výpočetního prvku, který nazval ADALINE (ADaptive LINear Element). Tento model byl vybaven novým výkonným učícím pravidlem, které se až doposud využívá. Widrow se svými studenty demonstroval funkčnost ADALINE na mnoha jednoduchých typových příkladech. Widrow také založil první firmu (Me-mistor Corporation) orientovanou na hardware neuropočítačů, která v první polovině 60. let vyráběla a prodávala neuropočítače a jejich komponenty.

1.2. 50-60 léta

Na přelomu 50. a 60. let dochází k úspěšnému rozvoji neurovýpočtů v oblasti návrhu nových modelů neuronových sítí a jejich implementací. Například Karl Steinbuch vyvinul model binární asociativní sítě [8] nebo Roger Barron a Lewey Gilstrap založili v roce 1960 první firmu zaměřenou na aplikace neurovýpočtů. Přes nesporné úspěchy dosažené v tomto období se obor neuronových sítí potýkal se dvěma zřejmými problémy.

- Za prvé, většina badatelů přistupovala k neuronovým sítím z experimentálního hlediska a zanedbávala analytický výzkum neuronových modelů.

- Za druhé, nadšení některých výzkumných pracovníků vedlo k velké publicitě neopodstatněných prohlášení jako například, že za několik málo let bude vyvinut umělý mozek. Tyto skutečnosti diskreditovaly neuronové sítě v očích odborníků z jiných oblastí a odradily vědce a inženýry, kteří se o neurovýpočty zajímali. Navíc samotný obor neuronových sítí se vyčerpal a další pokrok v této oblasti by býval vyžadoval radikálně nové myšlenky a postupy. Nejlepší odborníci oblast neuronových sítí opouštěli a začali se zabývat příbuznými obory umělé inteligence.

Poslední epizodou tohoto období byla kampaň vedená Marvinem Minským a Seymourem Papertem, kteří využili svého vlivu, aby diskreditovali výzkum neuronových sítí, nacházející se v krizi, ve snaze převést finanční zdroje z této oblasti na jiný výzkum v umělé inteligenci. V té době koloval rukopis jejich výzkumné zprávy, která napomáhala tomuto záměru. Uvedený rukopis pak byl v upravené formě publikován v roce 1969 pod názvem *Perceptrons*. V této knize Minsky a Papert využili pro svoji argumentaci známého triviálního faktu, že jeden perceptron nemůže počítat jednoduchou logickou funkci. Tento problém lze sice vyřešit vytvořením dvouvrstvé sítě se třemi neurony, ale pro vícevrstvý perceptron nebyl v té době znám učící algoritmus. Autoři z toho nesprávně vyvodili, že takový algoritmus vzhledem ke komplikovanosti funkce, kterou vícevrstvá síť počítá, snad ani není možný. Jejich tvrzení bylo všeobecně přejato a považováno za matematicky dokázané. Kampaň Minského a Paperta byla úspěšná, výzkum neuronových sítí již nebyl dále dotován a neurovýpočty byly považovány za neperspektivní.

1.3. 80 léta

Počátkem 80. let se badatelé v oblasti neurovýpočtů osmělili a začali podávat vlastní grantové projekty zaměřené na vývoj neuropočítačů a jejich aplikace. Zasluhou programového manažera Ira Skurnicka začala v roce 1983 americká grantová agentura DARPA (Defense Advanced Research Projects Agency) finančně podporovat výzkum neuronových sítí a její příklad v krátké době následovaly další organizace podporující základní i aplikovaný výzkum.

Další zásluhu na vývoji oboru neuronových sítí měl světově uznávaný fyzik John Hopfield, který se v této době začal zabývat neurovýpočty. V letech 1982 až 1984 dokázal souvislost některých modelů neuronových sítí s fyzikálními modely magnetických materiálů. Svými přednáškami, které měl po celém světě, získal pro neuronové sítě stovky kvalifikovaných vědců, matematiků a technologů.

V roce 1986 publikovali své výsledky badatelé z tzv. „PDP skupiny“ (Parallel Distributed Processing Group). Zde se objevil článek Rumelharta, Geoffreyho Hintona a Ronalda Williamse [9], kteří v něm popsali učící algoritmus zpětného šíření chyby (backpropagation) pro vícevrstvou neuronovou síť a vyřešili tak problém, který se Minskému a Papertovi v 60. letech jevil jako nepřekonatelná překážka pro využití a další rozvoj neuronových sítí. Tento algoritmus je dosud nejpoužívanější učící metodou neuronových sítí.

V roce 1987 se v San Diegu konala první větší konference specializovaná na neuronové sítě (IEEE International Conference on Neural Networks), na které bylo 1700 účastníků, a byla založena mezinárodní společnost pro výzkum neuronových sítí INNS (International Neural Network Society).

2. Biologický neuron a neuronová síť

Původním cílem výzkumu neuronových sítí byla snaha pochopit a modelovat, jakým způsobem funguje lidský mozek. Neurofyziologické poznatky umožnily vytvořit zjednodušené matematické modely, které se dají využít pro neurovýpočty při řešení praktických úloh z umělé inteligence. To znamená, že neurofyziologie zde slouží jen jako zdroj inspirací a navržené modely neuronových sítí jsou již dále rozvíjeny bez ohledu na to, zda modelují lidský mozek. Přesto, je-li to užitečné, lze se k této analogii vracet pro nové inspirace nebo je možné ji využít při popisu vlastností matematického modelu.


Nervová soustava člověka (obecně živých organismů) zprostředkovává vztahy mezi vnějším prostředím a organismem, i mezi jeho částmi a zajišťuje tak příslušnou reakci na vnější podněty i na vnitřní stavy organismu. Tento proces probíhá šířením vzruchů z jednotlivých čidel, tzv. receptorů, které umožňují přijímat mechanické, tepelné, chemické a světelné podněty, směrem k jiným nervovým buňkám, které tyto signály zpracovávají a přivádí k příslušným výkonným orgánům, tzv. efektorům. Tyto vzruchy se po projekčních drahách, kde dochází k prvnímu předzpracování, kompresi a filtraci informace, dostávají až do mozkové kůry, která je nejvyšším řídicím centrem nervového systému. Na povrchu mozku můžeme rozlišit celkem šest primárních vzájemně propojených projekčních oblastí odpovídajících přibližně smyslům, ve kterých dochází k paralelnímu zpracování informace.

2.1. Biologický neuron

Základním stavebním funkčním prvkem nervové soustavy je nervová buňka, tzv. neuron. Mozková kůra člověka je tvořena asi 13 až 15 miliardami neuronů, z nichž každý může být spojen s přibližně 5000 jinými neurony. Neurony jsou samostatné buňky určené k přenosu, zpracování a uchování informací nutných pro realizaci životních funkcí organismu. Struktura neuronu je schematicky znázorněna na obrázku 1.1.

2.1.1. Tělo neuronu

Tělo neuronu se nazývá soma, obsahuje jádro, ribozomy, lysozomy a endoplazmatické retikulum. Zajišťuje proteosyntézu a sestavování proteinových komplexů.



Obr. 1.1.: Biologický neuron

2.1.2. Axon

Axon je obvykle pouze jeden na každém neuronu, může jít o velmi dlouhé vlákno (u člověka až 1 m). Axon přenáší vzruchy z těla neuronu do dalších neuronů. Transport proteinů do odlehlých částí axonu z těla buňky zajišťují intermediární filamenty a mikrotubuly. Povrch nervových vláken je obalen speciálními pochvami. Některá periferní nervová vlákna mají pouze tzv. Schwannovu pochvu, tvořenou Schwannovými buňkami. Jiná vlákna mají mezi neurolemmou a Schwannovou pochvou tzv. pochvu myelinovou. Myelinová

pochva vzniká mnohonásobným spirálovitým ovinutím Schwannových buněk kolem nervového vlákna. Vytvoří se tzv. internodia - místa bohatá na myelin. Mezi internodií jsou Ranvierovy zářezy, kde myelin chybí. Vzdálenost mezi nimi a délka internodií se pohybuje v desetinách mm.

Vodivost nervových vláken je závislá na síle myelinových pochev. Čím je nervové vlákno a myelinová pochva silnější, tím rychleji vede vzruchy. Myelinová i Schwannova pochva zabraňují šíření nervových vzruchů mezi sousedními vlákny. Pochvy izolují jednotlivá vlákna. Jak bylo uvedeno výše, nervová vlákna se větví. Axon zpravidla vede signál (vzruch) eferentně (tj. směrem od těla neuronu). Jeho větvičky jsou zakončeny knoflíkovitými útvary tzv. boutony, které se přikládají na tělo či dendrit dalšího neuronu či na jinou buňku zvanou obecně efektor. Toto spojení se nazývá synapse (viz dále).

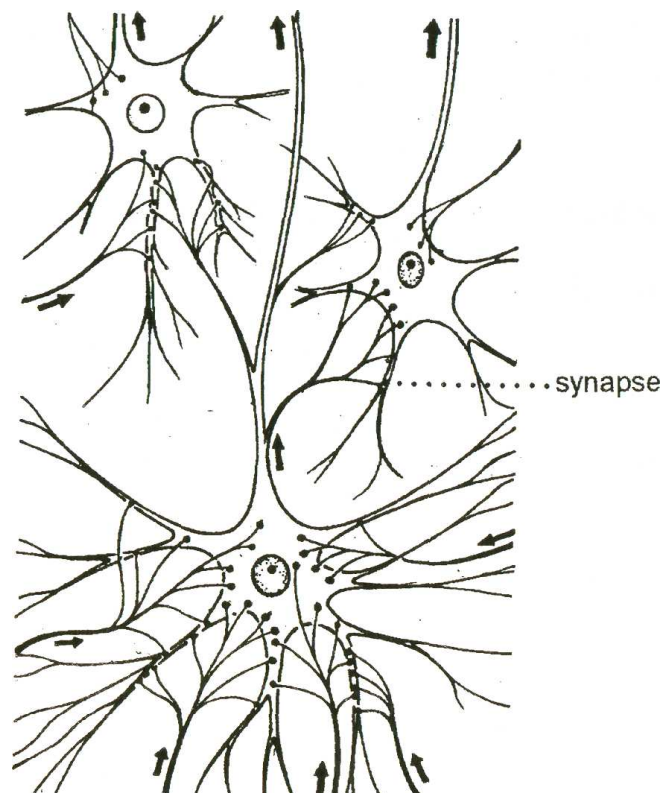
2.1.3. Dendrity

Neuron má zpravidla větší počet těchto vstupních vláken, která přijímají signály ze sensorických buněk nebo z axonů jiných neuronů a přenášejí je do těla buňky. Jsou kratší než axon. Větvičky dendritů obvykle začínají vnímavým zakončením (u periferních vláken obecně zvaným smyslový receptor), ať už začínají volně (např. vnímání bolesti) nebo jsou speciálně formována (např. hmatová tělíška). Jednotlivé větvičky se spojují v aferentní vlákno přivádějící vzruch do těla neuronu. Často je receptorem samo uzpůsobené tělo neuronu (např. neurony sítnice, čichové neurony).

2.2. Biologická neuronová síť

Neuron je přizpůsoben pro přenos signálů tak, že kromě vlastního těla, tzv. sómatu, má i vstupní a výstupní přenosové kanály: dendrity a axon. Z axonu obvykle odbočuje řada větví, tzv. terminálů, zakončených blánou, která se převážně stýká s výběžky, tzv. trny, dendritů jiných neuronů, jak je naznačeno na obrázku 1.2. K přenosu informace pak slouží unikátní mezineuronové rozhraní, tzv. synapse. Míra synaptické propustnosti je nositelem všech význačných informací během celého života organismu.

Z funkčního hlediska lze synapse rozdělit především na tzv. excitační, které umožňují rozšíření vzruchu v nervové soustavě, a na tzv. inhibiční, které způsobují jeho útlum. Paměťová stopa v nervové soustavě vzniká pravděpodobně právě zakódováním synaptických vazeb na cestě mezi receptorem a efektozem. Šíření informace je umožněno tím, že sóma i axon jsou obaleny membránou, která má schopnost za jistých okolností generovat elektrické impulsy. Tyto impulsy jsou z axonu přenášeny na dendrity jiných neuronů synaptickými branami, které svojí propustností určují intenzitu podráždění dalších neuronů. Takto podrážděné neurony při dosažení určité hraniční meze, tzv. prahu, samy generují impuls a zajišťují tak šíření příslušné informace. Po každém průchodu signálu se synaptická propustnost mění, což je předpokladem paměťové schopnosti neuronů. Také propojení neuronů prodělává během života organismu svůj vývoj, v průběhu učení se vytváří nové paměťové stopy nebo při zapomínání se synaptické spoje přerušují.




Obr. 1.2.: Biologická neuronová síť

3. Matematický model neuronu a neuronové sítě

3.1. Formální neuron

Základem matematického modelu neuronové sítě je formální neuron, který získáme přeformulováním zjednodušené funkce neurofyziologického neuronu do matematické řeči. Jeho struktura je schematicky znázorněna na obrázku 3.1. Formální neuron má n obecně reálných vstupů x_1, \dots, x_n , které modelují dendrity. Vstupy jsou ohodnoceny odpovídajícími obecně reálnými synaptickými váhami w_1, \dots, w_n , které určují jejich propustnost.



Obr.: 3.1.: Formální neuron

Synaptické váhy mohou být záporné, čímž se vyjadřuje jejich inhibiční charakter. Vážená suma vstupních hodnot s váhou w_i představuje vnitřní potenciál neuronu:

$$\xi = \sum_{i=1}^n w_i x_i. \quad (1)$$

Hodnota vnitřního potenciálu ξ po dosažení prahové hodnoty h indikuje výstup (stav) neuronu y , který modeluje elektrický impuls axonu. Nelineární nárůst výstupní hodnoty $y = \sigma(\xi)$ při dosažení prahové hodnoty potenciálu h je dán tzv. aktivační (přenosovou) funkcí σ . Nejjednodušším typem aktivační funkce je tzv. ostrá nelinearita, která

$$\sigma(\xi) = \begin{cases} 1 & \text{jestliže } \xi \geq h \\ 0 & \text{jestliže } \xi < h. \end{cases} \quad (2)$$

Formální úpravou lze docílit toho, že funkce σ bude mít nulový práh a vlastní práh neuronu se záporným znaménkem budeme chápat jako váhu, tzv. bias $w_0 = -h$ dalšího formálního vstupu $x_0 = 1$ s konstantní jednotkovou hodnotou. Matematická funkce neuronu je potom dána vztahem:

$$y = \sigma(\xi) = \begin{cases} 1 & \text{jestliže } \xi \geq 0 \\ 0 & \text{jestliže } \xi < 0 \end{cases}, \quad \text{kde } \xi = \sum_{i=0}^n w_i x_i. \quad (3)$$

3.2. Matematický model neuronové sítě

Matematická neuronová síť se skládá z formálních neuronů, které jsou vzájemně propojené tak, že výstup neuronu je vstupem obecně více neuronů podobně, jako terminály axonu biologického neuronu jsou přes synaptické vazby spojeny s dendrity jiných neuronů. Počet neuronů a jejich vzájemné propojení v síti určuje tzv. architekturu (topologii) neuronové sítě. Z hlediska využití rozlišujeme v síti vstupní, pracovní (skryté, mezilehlé) a výstupní neurony. Lze zjednodušeně říci, že v neurofyziologické analogii vstupní neurony odpovídají receptorům, výstupní neurony efektorům a propojené pracovní neurony mezi nimi vytváří příslušné dráhy (cesty), po kterých se šíří vlastní vzruchy. Šíření a zpracování informace na cestě v síti je umožněno změnou stavů neuronů ležících na této cestě. Stavů všech neuronů v síti určují tzv. stav neuronové sítě a synaptické váhy všech spojů představují tzv. konfiguraci neuronové sítě.

Neuronová síť se v čase vyvíjí, mění se propojení a stav neuronů, adaptují se váhy. V souvislosti se změnou těchto charakteristik v čase je účelné celkovou


dynamiku neuronové sítě rozdělit do tří dynamik a uvažovat pak tři režimy práce sítě: organizační (změna topologie), aktivní (změna stavu) a adaptivní (změna konfigurace). Toto dělení neodpovídá neurofyzilogické skutečnosti, protože v nervové soustavě probíhají příslušné změny současně. Uvedené dynamiky neuronové sítě jsou obvykle zadány počátečním stavem a matematickou rovnicí, resp. pravidlem, které určuje vývoj příslušné charakteristiky sítě (topologie, stav, konfigurace) v čase. Změny, které se řídí těmito zákonitostmi, probíhají v odpovídajících režimech práce neuronové sítě.

Konkretizací jednotlivých dynamik pak obdržíme různé modely neuronových sítí vhodné pro řešení určitých tříd úloh. To znamená, že pro specifikaci konkrétního modelu neuronové sítě stačí, když definujeme jeho organizační, aktivní a adaptivní dynamiku.

3.2.1. Organizační dynamika


Organizační dynamika specifikuje architekturu sítě a její případnou změnu. Změna topologie se většinou uplatňuje v rámci adaptivního režimu tak, že síť je v případě potřeby rozšířena o další neurony a příslušné spoje. Avšak organizační dynamika převážně předpokládá pevnou architekturu neuronové sítě, která se již nemění.

Rozlišujeme v zásadě dva typy architektury: cyklická (resp. rekurentní) a acyklická (resp. dopředná) síť. V případě cyklické topologie existuje v síti skupina neuronů, která je zapojena v kruhu (tzv. cyklus). To znamená, že v této skupině neuronů je výstup prvního neuronu vstupem druhého neuronu, jehož výstup je opět vstupem třetího neuronu atd., až výstup posledního neuronu v této skupině je vstupem prvního neuronu. Nejjednodušším příkladem cyklu je zpětná vazba neuronu, jehož výstup je zároveň jeho vstupem. Nejvíce cyklů je v tzv. úplné topologii cyklické neuronové sítě, kde výstup libovolného neuronu je vstupem každého neuronu. Příklad obecné cyklické neuronové sítě je na obrázku 3.2, kde jsou vyznačeny všechny cykly.




Obr. 3.2: Cyklická architektura neuronové sítě [2]

V acyklických sítích naopak cyklus neexistuje a všechny cesty vedou jedním směrem. Příklad acyklické neuronové sítě je na obrázku 3.3, kde je vyznačena nejdelší cesta.



Obr. 3.3: Acyklická architektura neuronové sítě [2]

U acyklické neuronové sítě lze neurony vždy rozdělit do vrstev, které jsou uspořádány (např. nad sebou) tak, že spoje mezi neurony vedou jen z nižších vrstev do vyšších a obecně mohou přeskočit jednu nebo více vrstev. Speciálním případem takové architektury je tzv. vícevrstvá neuronová síť. V této síti je nultá (dolní), tzv. vstupní vrstva tvořena vstupními neurony a poslední (horní), tzv. výstupní vrstva se skládá z výstupních neuronů. Ostatní, tzv. skryté (mezilehlé) vrstvy jsou složeny ze skrytých neuronů. Jak už bylo naznačeno, vrstvy číslujeme od nuly, která odpovídá vstupní vrstvě. Tu potom nepočítáme do počtu vrstev sítě (např. dvouvrstvá neuronová síť se skládá ze vstupní, jedné skryté a výstupní vrstvy). V topologii vícevrstvé sítě jsou neurony jedné vrstvy spojeni se všemi neurony bezprostředně následující vrstvy (příp. chybějící spoje lze implicitně chápat jako spoje s nulovými váhami). Proto architekturu takové sítě lze zadat jen počty neuronů v jednotlivých vrstvách, typicky oddělenými pomlčkou, v pořadí od vstupní k výstupní vrstvě. Také cesta v takové síti vede směrem od vstupní vrstvy k výstupní, přičemž obsahuje po jednom neuronu z každé vrstvy. Příklad architektury třívrstvé neuronové sítě 3-4-3-2 s jednou vyznačenou cestou je na obrázku 2.3, kde kromě vstupní a výstupní vrstvy jsou dvě skryté vrstvy.



Obr. 3.4: Příklad architektury vícevrstvé neuronové sítě 3-4-3-2

3.2.2. Aktivní dynamika

Aktivní dynamika specifikuje počáteční stav sítě a způsob jeho změny v čase při pevné topologii a konfiguraci. V aktivním režimu se na začátku nastaví stavy vstupních neuronů na tzv. vstup sítě a zbylé neurony jsou v uvedeném počátečním stavu. Všechny možné vstupy, resp. stavy sítě, tvoří tzv. vstupní prostor, resp. stavový prostor, neuronové sítě. Po inicializaci stavu sítě probíhá vlastní výpočet. Obecně se uvažuje spojitý vývoj stavu neuronové sítě v čase a hovoří se o tzv. spojitém modelu, kdy stav sítě je (spojitou) funkcí času, která je obvykle v aktivní dynamice zadána diferenciální rovnicí. Většinou se však předpokládá diskrétní čas, tj. na počátku se síť nachází v čase 0 a stav sítě se mění jen v čase 1,2,3,... V každém takovém časovém kroku je podle daného pravidla aktivní dynamiky vybrán jeden neuron (tzv. sekvenční výpočet) nebo více neuronů (tzv. paralelní výpočet), které aktualizují (mění) svůj stav na základě svých vstupů, tj. stavů sousedních neuronů, jejichž výstupy jsou vstupy aktualizovaných neuronů. Podle toho, zda neurony mění svůj stav nezávisle na sobě nebo je jejich aktualizace řízena centrálně, rozlišujeme asynchronní a synchronní modely neuronových sítí. Stav výstupních neuronů, který se obecně mění v čase, je tzv. výstupem neuronové sítě (tj. výsledkem výpočtu). Obvykle se však uvažuje taková aktivní dynamika, že výstup sítě je po nějakém čase konstantní a neuronová síť tak v aktivním režimu realizuje nějakou funkci na vstupním prostoru, tj. ke každému vstupu sítě vypočítá právě jeden výstup. Tato tzv. funkce neuronové sítě je tedy dána aktivní dynamikou, jejíž rovnice parametricky závisí na topologii a konfiguraci, které se v aktivním režimu nemění. Je zřejmé, že v aktivním režimu se neuronová síť využívá k vlastním výpočtům.

3.2.3 Adaptivní dynamika

Adaptivní dynamika specifikuje počáteční konfiguraci sítě a jakým způsobem se mění váhy v síti v čase. Všechny možné konfigurace sítě tvoří váhový prostor neuronové sítě. V adaptivním režimu se tedy na začátku nastaví váhy všech spojů v síti na počáteční konfiguraci (např. náhodně). Po inicializaci konfigurace sítě probíhá vlastní adaptace. Podobně jako v aktivní dynamice se obecně uvažuje spojitý model se spojitým vývojem konfigurace neuronové sítě v čase, kdy váhy

sítě jsou (spojitou) funkcí času, která je obvykle v adaptivní dynamice zadána diferenciální rovnicí.

Funkce sítě v aktivním režimu závisí na konfiguraci. Cílem adaptace je nalézt takovou konfiguraci sítě ve váhovém prostoru, která by v aktivním režimu realizovala předepsanou funkci. Jestliže aktivní režim sítě se využívá k vlastnímu výpočtu funkce sítě pro daný vstup, pak adaptivní režim slouží k učení („programování“) této funkce. Existují stovky úspěšných učících algoritmů pro různé modely neuronových sítí. Například nejznámější a nejpoužívanější učící algoritmus je backpropagation pro vícevrstvou neuronovou síť [2].

Učení neuronové sítě představuje většinou složitý nelineární optimalizační problém, jehož řešení je i pro menší úlohy časově velmi náročné (desítky hodin i dnů výpočtu na PC).

4. Aplikace neuronových sítí


4.1 Využití neuronových sítí

Neuronové sítě lze přirozeným způsobem použít k rozpoznávání obrazců, a to pro speciální případ — rozpoznání (např. naskenovaných) psaných, resp. tištěných znaků (číslic, písmen apod.). V tomto případě se takový obraz znaku (např. pomocí klasického počítače) nejprve odseparuje od okolního textu (např. se určí krajní body obrazu) a potom se znormuje, tj. zobrazí do standardizované matice (např. $15 \times 10 = 150$) bodů. Jednotlivé body pak odpovídají vstupům neuronové sítě, které jsou např. aktivní, právě když čára v obrazu zasahuje příslušné body. Každý výstupní neuron v síti představuje možný znak, který je rozpoznán, právě když je tento neuron aktivní. Tréninkovou množinu lze např. vytvořit přepsáním nějakého textu, který je již k dispozici v počítači (odpovídá požadovaným výstupům tréninkových vzorů, tj. identifikovaným znakům), takovým způsobem (např. rukou), pro který budeme neuronovou sít' k rozpoznávání potřebovat (představuje odpovídající příklady obrazových vstupů tréninkových vzorů). Neuronovou sít' lze pak pomocí této tréninkové množiny učit tak dlouho, dokud není sama schopna rozpoznávat příslušné znaky. Tímto postupem můžeme v relativně krátké době docílit spolehlivosti např. 95% správně rozpoznávaných znaků. Podobný postup lze využít např. v robotice pro zpracování vizuálních informací či při vyhodnocování družicových snímků a podobně.

Další možnou oblastí využití neuronových sítí je řízení složitých zařízení v dynamicky se měnících podmínkách. Demonstračním příkladem řídicího systému popisovaného v literatuře [10] je autopilot automobilu, který se v počítačové simulaci pohybuje na dvoupruhové dálnici spolu s auty jedoucími stejným směrem. Auto řízené neuronovou sítí určovalo na základě vzdáleností a rychlostí nejbližších aut v obou pruzích svoji vlastní rychlost a změnu pruhu. Dále neuronová sít' ovládala volant podle zakřivení dálnice, polohy auta v pruhu a aktuálního úhlu volantu. Je zajímavé, že neuronová sít' se kromě úspěšného řízení vozidla včetně předjíždění naučila i různé zvyky a styl jízdy (např. riskantní rychlá jízda a časté předjíždění nebo naopak opatrná pomalá jízda) podle řidičů — trenérů, od kterých byly získávány tréninkové vzory.

Jinou důležitou aplikační oblastí neuronových sítí je predikce a příp. následné rozhodování. Typickými příklady z této oblasti jsou předpověď počasí, vývoj cen akcií na burze, spotřeba elektrické energie apod.

Další oblastí aplikace neuronových sítí je transformace signálů. Příkladem je systém NETtalk. Systém pro převod anglicky psaného textu na mluvený signál. Tento systém je založen na dvouvrstvé síti 203-80-26 se 7 x 29 vstupními neurony pro zakódování kontextu 7 písmen psaného textu (každému z 26 písmen anglické abecedy a čárce, tečky a mezeře odpovídá 1 neuron, který je při jejich výskytu aktivní), 80 skrytými neurony v mezilehlé vrstvě a 26 výstupními neurony reprezentujícími fonémy odpovídajícího mluveného signálu. Funkce sítě je znázorněna na obrázku 4.1, kde se vstupní text postupně přesouvá u vstupních neuronů po jednom písmenu zprava doleva, přitom je aktivní právě výstupní neuron, který reprezentuje foném odpovídající prostřednímu ze sedmi písmen vstupního kontextu. V našem příkladě se čte prostřední písmeno „C“ v anglickém slově CONCEPT s výslovností ['konsept], kterému odpovídá foném [s]. Stejné písmeno „C“ na začátku tohoto slova však v daném kontextu odpovídalo fonému [k]. Úspěšná implementace systému NETtalk vedla ke snaze vytvořit systém založený na neuronové síti s obrácenou funkcí, která by převáděla mluvený jazyk do psané formy (tzv. fonetický psací stroj).



Obr. 4.1: Systém NETtalk [2]

Jiným příkladem uplatnění neuronových sítí je analýza signálů jako například EKG, EEG. Spojitý signál je vzorkován ve stejných časových intervalech a několik posledních diskrétních hodnot úrovně signálu slouží jako vstup např. do dvouvrstvé sítě. Naučená neuronová síť je schopna identifikovat specifický tvar signálu, který je důležitý pro diagnostiku.

4.2 Neuropočítač a PC

Odlišná architektura neuronových sítí vyžaduje speciální hardwarovou realizaci. V této souvislosti hovoříme o tzv. neuropočítačích. Avšak vzhledem k rozšířenosti klasických počítačů a kvůli problémům spojeným s hardwarovou realizací neuronových sítí zatím nejjednodušší implementací neuronových sítí, se kterou se nejčastěji (zvláště v České republice) setkáváme, je tzv. netware, což je software pro klasické počítače, který modeluje práci neuronové sítě. Jedná se většinou o demonstrační programy s efektním uživatelským interfacem, které simulují práci nejznámějších modelů neuronových sítí na jednoduchých příkladech. V některých již dokonalejších programech je možné zadat vlastní aktivní i adaptivní dynamiku, což umožňuje relativně rychle přizpůsobit model neuronové sítě danému praktickému problému nebo ověřit použitelnost navrženého nového modelu. Existují i programovací jazyky (a jejich překladače) pro klasické počítače, které podporují programovou implementaci neuronových algoritmů. Příkladem takového programovacího jazyka je AXON, který je podobný jazyku C. Dokonalejší netware většinou podporuje využití specializovaných koprocesorů (které je možno např. připojit k PC), které efektivně implementují neuronové funkce a urychlují časově náročné učení.

Vlastní neuropočítače většinou nepracují samostatně, ale jsou napojeny na klasické počítače, které mohou realizovat např. uživatelský interface. To je dáno především tím, že neuropočítače nejsou používány jako univerzální počítače, ale převážně fungují jako specializovaná zařízení pro řešení specifických úloh. Malé neuropočítače jsou spojeny přímo se sběrnici klasického počítače a větší se mohou uplatnit jako servery na lokální síti. Podle způsobu aktualizace parametrů neuronové sítě rozdělujeme neuropočítače na spojitě a diskrétní a podle typu reprezentace těchto číselných parametrů máme analogové, digitální, resp. hybridní

(kombinace analogových a digitálních) neuropočítače. Zřídka kdy jeden neuron v implementované síti odpovídá jednomu procesoru neuropočítače (tzv. plně implementované neuropočítače), což se využívá pro velmi rychlé výpočty v reálném čase. Většinou se konstruují tzv. virtuální neuropočítače, kde jeden procesor vykonává práci stovek i tisíců neuronů části implementované neuronové sítě.

Z hlediska technologie je většina neuropočítačů založena na klasické mikroelektronice, kde neurony odpovídají hradlům (např. speciálním tranzistorům) a váhy synaptických spojů jsou reprezentovány rezistorovými vazbami. Tento přístup však s sebou přináší technické problémy jako je velká hustota propojení neuronů nebo adaptovatelnost vah u všech těchto spojů. Proto adaptivní režim neuronové sítě je někdy předem realizován odděleně pomocí dostupného netwaru na klasickém počítači a výsledná konfigurace sítě je napevno zapojena do příslušného obvodu neuropočítače. Také se stále více uplatňuje optoelektronika a dlouhodobější výhledy počítají s úplně odlišnými technologiemi, jako například molekulární elektronika, hybridní biočipy apod.

4.3 Použití neuronových sítí pro kompresi dat

4.3.1 Základní pojmy

Kódování

Proces, který převádí zprávu vyjádřenou v jedné abecedě na zprávu vyjádřenou v jiné abecedě. Aby bylo možné zprávu u příjemce opět obnovit, musí být takový převod jednoznačný a nesmí měnit obsah zprávy ani množství informace. Může však měnit množství redundance. Důvody, pro kódování zprávy jsou dva. Jedním z nich je příprava zprávy na přenos kanálem, který používá abecedu jiné mohutnosti. Druhým důvodem je snižování redundance (komprese dat).

Huffmanovo kódování

Algoritmus byl publikován v roce 1952 [11] a přes svoje stáří je stále jedním z nejpoužívanějších. Znaky s vysokou frekvencí výskytu kóduje malým počtem symbolů a naopak znaky vyskytující se zřídka jsou kódovány dlouhými

řetězci. Jde tedy o kód s proměnnou délkou znaků. Aby mohl příjemce obnovit kódovanou zprávu, musí mít k dispozici kódovací strom, kterým tato zpráva byla zakódována.

Existují dva přístupy řešení tohoto problému:


a) Statická metoda – odesílatel zjistí četnosti výskytu jednotlivých znaků a zkonstruuje kódovací tabulku. Tu potom v nekomprimované podobě připojí ke zprávě. To se zřejmě negativně projeví na celkové účinnosti při kompresi krátkých zpráv. Proto je vhodné krátké zprávy spojovat do delších bloků a ty potom komprimovat jako jeden celek. I tento způsob má nevýhody v případě, kdy spojované zprávy budou vzájemně protichůdně ovlivňovat četnosti znaků, což způsobí zhoršení účinnosti. Tomu lze čelit klasifikací zpráv do tříd a spojovat do celků jen zprávy ze stejné třídy. Hlubším zkoumáním takových tříd lze dospět k závěru, že lze uvažovat o univerzálních kódovacích tabulkách pro některé třídy. Pak by stačilo místo kódovací tabulky připojit ke zprávě jenom identifikaci třídy.

b) Dynamická metoda – eliminuje problém přenosu kódovacího stromu, ovšem za cenu horšího kompresního poměru. Odesílatel totiž nezjišťuje jednotlivé četnosti, ale začne kódovat pomocí implicitní kódovací tabulky, kterou má k dispozici i příjemce. Po každém přeneseném znaku si odesílatel i příjemce zvýší odpovídající četnost a vytvoří novou kódovací tabulku, platnou pro přenos dalšího znaku. Implicitní tabulka je nejčastěji vytvářena za předpokladu stejných četností pro všechny znaky. Opět se nabízí zdokonalení, založené na výše popsané klasifikaci a použití předspočítaných četností, které lépe reflektují situaci v jednotlivých třídách.

4.3.2 Kompresce a neuronové sítě

Často zmiňovanou aplikací neuronových sítí je komprese dat. Princip je poměrně jednoduchý. Použijeme perceptronovou síť, která má stejný počet vstupních a výstupních neuronů a v některé skryté vrstvě má počet neuronů menší. takovou síť učíme odpovídat na identitu předkládaných dat. Jakmile je síť naučena, rozdělíme ji v místě výstupů zmíněné skryté vrstvy na dvě části. Dostaneme tak dvě nové sítě – původně vstupní polovina sítě bude nyní sloužit jako kompresor,

druhá část jako dekompresor. Příklad takové sítě s jednou skrytou vrstvou o třech neuronech, vstupní a výstupní vrstvou o čtyřech neuronech je znázorněn na obrázku 4.2.



Obr: 4.2: Komprese pomocí neuronové sítě

S komprimovanými daty je nutné přenášet i váhy dekompresní sítě, aby bylo možné obnovit původní zprávu. Nevýhodou je, že tento přístup je založen na pevném, předem stanoveném, kompresním poměru, daném topologií použité sítě. Je zřejmé, že pokud bude počet neuronů ve skryté vrstvě příliš malý, nelze zajistit úplné naučení sítě na identitu. V konečném důsledku to znamená ztrátovou kompresi, což je obecně nepřijatelné. Problém pevného kompresního poměru lze řešit zavedením dynamické správy topologie sítě ve skryté vrstvě. Na počátku učení stanovíme počet neuronů skryté vrstvy stejný jako ve vstupní vrstvě. Potom je schopnost sítě naučit se identitě triviálně zaručena. V průběhu učení budeme sledovat aktivity jednotlivých neuronů skryté vrstvy a slučovat ty, které se chovají podobným způsobem a mají podobné váhy. Tímto postupem lze najít odpovídající topologii při zachování schopnosti úplného naučení sítě na identitu pro danou množinu dat. Je-li trénovací množina příliš velká, lze očekávat horší kompresní


poměr. V opačném případě bude nutné síť často doučovat nové vzory. Po každém doučení je však nutné rozšířit komprimovaný kód o informace o změně dekompresní sítě. Nezanedbatelnou roli hraje skutečnost, že vlastní učení sítě je v případě sekvenčního zpracování instrukcí časově náročné. Z těchto důvodů jsou stále preferovány klasické kompresní metody a teorie komprese dat neuronovou sítí zatím jen prezentuje možnosti a schopnosti neuronových sítí. Tato situace se však může změnit s masovým příchodem paralelních systémů. Toto využití neuronových sítí bývá často spojováno s kompresí obrazových dat, kde ztrátovost nehraje tolik závažnou roli.

5. Klasické modely neuronových sítí

5.1. Síť perceptronů

Historicky prvním úspěšným modelem neuronové sítě byla síť perceptronů.

Organizační dynamika této sítě specifikuje na začátku pevnou architekturu jednovrstvé sítě typu n-m. To znamená, že síť se skládá z n vstupních neuronů, z nichž každý je vstupem každého z m výstupních neuronů, jak je naznačeno na obrázku 5.1.



Obr 5.1: Architektura sítě perceptronů

Aktivní dynamika sítě perceptronů určuje způsob výpočtu funkce sítě. V tomto případě se reálné stavy neuronů ve vstupní vrstvě nastaví na vstup sítě a výstupní neurony počítají svůj binární stav, který určuje výstup sítě. To znamená, že každý perceptron nejprve vypočte svůj vnitřní potenciál jako příslušnou afinní kombinaci vstupů:

$$\xi_j = \sum_{i=0}^n w_{ji} x_i \quad j = 1, \dots, m \quad (4)$$

jejíž koeficienty $\mathbf{w} = (w_{10}, \dots, w_{1n}, \dots, w_{m0}, \dots, w_{mn})$ tvoří konfiguraci sítě.

V **adaptivním režimu** je požadovaná funkce sítě perceptronů zadána tréninkovou množinou

$$\mathcal{T} = \left\{ (\mathbf{x}_k, \mathbf{d}_k) \left| \begin{array}{l} \mathbf{x}_k = (x_{k1}, \dots, x_{kn}) \in R^n \\ \mathbf{d}_k = (d_{k1}, \dots, d_{km}) \in \{0,1\} \end{array} \right. k = 1, \dots, p \right\}, \quad (5)$$

kde \mathbf{x}_k je reálný vstup k -tého tréninkového vzoru a \mathbf{d}_k je odpovídající požadovaný binární výstup. Cílem adaptace je, aby síť pro každý vstup \mathbf{x}_k ($k=1, \dots, p$) z tréninkové množiny odpovídala v aktivním režimu požadovaným výstupem \mathbf{d}_k , tj. aby platilo

$$y(\mathbf{w}, \mathbf{x}_k) = \mathbf{d}_k \quad k = 1, \dots, p. \quad (6)$$

Samozřejmě podmínku (6) nelze vždy splnit, protože každou funkci lze počítat jedním perceptronem nebo tréninková množina nemusí být funkcí (tj. k jednomu vstupu jsou požadované dva výstupy). V takovém případě se snažíme, aby se síť naučila co nejvíce vzorů. V praxi je také někdy lepší, aby se síť nenaučila tréninkovou množinu stoprocentně, protože příkladové vzory nemusí být úplně přesné.

Na začátku adaptace v čase 0 jsou váhy konfigurace $\mathbf{w}(0)$ nastaveny náhodně blízko nuly. Síť perceptronů má diskrétní adaptivní dynamiku. V každém časovém kroku učení $t = 1, 2, 3, \dots$ je síti předložen jeden vzor z tréninkové množiny a síť se ho snaží naučit, tj. adaptuje podle něj své váhy. Pořadí vzorů při učení je dáno tréninkovou strategií, kterou lze například porovnat s lidským učením. Některý student si na zkoušku několikrát přečte učebnici, jiný se hned při prvním čtení vše důkladně učí a oba si na konci opakují části, které neumí.

Adaptace sítě perceptronů obvykle probíhá v tréninkových cyklech, ve kterých se systematicky prochází všechny vzory tréninkové množiny (popř. každý vzor i vícekrát za sebou).

Rychlost učení sítě je taková, že se většinou na začátku volí malá rychlost učení, která později během adaptace roste. To v analogii s přípravou studenta na zkoušku odpovídá prvnímu povrchnímu seznámení s předmětem a pozdějšímu důkladnému doučení detailů.

Vzhledem k tomu, že perceptronová síť může počítat jen omezenou třídu funkcí, je význam tohoto modelu spíše teoretický. Tento jednoduchý model je však základem složitějších modelů jako je obecná vícevrstvá síť s učícím algoritmem backpropagation.

5.2. Vícevrstvá síť

Nejnámější a nejpoužívanější model neuronové sítě je vícevrstvá neuronová síť, který se používá přibližně v 80% všech aplikací neuronových sítí. Tento model je zobecněním sítě perceptronů pro architekturu se skrytými vrstvami (tzv. vícevrstvý perceptron). Vzhledem k rozšířenosti vícevrstvého perceptronu a jeho určitým nedostatkům existuje mnoho variant tohoto modelu, které se snaží zlepšit jeho vlastnosti.

Organizační dynamika vícevrstvého perceptronu specifikuje na začátku pevnou topologii vícevrstvé neuronové sítě. Standardně se používá dvouvrstvá, resp. třívrstvá síť, protože význam skrytých neuronů a jejich vazeb, potřebný pro návrh speciální topologie není znám.

V aktivním režimu počítá vícevrstvá síť pro daný vstup funkci $y(\mathbf{w}): R^n \rightarrow (0,1)^m$, která je určena konfigurací \mathbf{w} . Výpočet probíhá podle následující diskrétní aktivní dynamiky. V čase 0 jsou odpovídající stavy vstupních neuronů $y_i (i \in X)$ nastaveny na vstup sítě a ostatní neurony nemají určen svůj stav. V čase $t > 0$ jsou vypočteny reálné hodnoty vnitřních potenciálů

$$\xi_j = \sum_{i \in J_{in}} w_{ji} y_i, \quad (7)$$

všech neuronů j , jejichž vstupy již mají určen svůj stav. To znamená, že v čase t jsou aktualizovány neurony v t -té vrstvě.

Adaptivní režim vícevrstvé sítě probíhá podobně jako u sítě perceptronu. Požadovaná funkce je opět zadána tréninkovou množinou (5). Chyba sítě $E(\mathbf{w})$ vzhledem k této tréninkové množině je definována jako součet parciálních chyb sítě $E_k(\mathbf{w})$ vzhledem k jednotlivým tréninkovým vzorům a závisí na konfiguraci sítě \mathbf{w} :

$$E(w) = \sum_{k=1}^p E_k(w). \quad (8)$$

5.3. MADALINE

Dalším historicky důležitým modelem neuronové sítě je MADALINE (multiple ADALINE), který byl navržen Widrowem a Hoffem. Základním prvkem tohoto modelu je neuron ADALINE (ADAPtive LINear Element), který je velmi podobný perceptronu. Proto je tento model neuronové sítě formálně téměř identický se sítí perceptronů, i když původně vychází z jiných principů.

Organizační dynamika MADALINE a značení parametrů sítě je stejné jako u sítě perceptronů, avšak místo perceptronu uvažujeme ADALINE.

Aktivní dynamika se u tohoto modelu liší tím, že výstupy sítě mohou být obecně reálné a jednotlivé ADALINE realizují lineární funkci, tj. chybí nelineární aktivační funkce. Funkce MADALINE je dána afinní kombinací vstupů:

$$y_j = \sum_{i=0}^n w_{ji} x_i \quad j = 1, \dots, m. \quad (9)$$

V **adaptivním režimu** je MADALINE zadána tréninkovou posloupností, kde jsou reálné vstupy tréninkových vzorů \mathbf{x}_k generovány náhodně s daným rozdělením pravděpodobností a u každého je dán požadovaný reálný vstup \mathbf{d}_k :


$$(\mathbf{x}_k, \mathbf{d}_k)_{k=1,2,\dots} \quad \text{kde} \quad \begin{aligned} \mathbf{x}_k &= (x_{k1}, \dots, x_{kn}) \in R^n \\ \mathbf{d}_k &= (d_{k1}, \dots, d_{km}) \in R^m. \end{aligned} \quad (10)$$

5.4. Sítě s kaskádovou architekturou

Tato podkapitola nám popíše sítě s kaskádovou architekturou, neboli kaskádové sítě.

Organizační dynamika (architektura) kaskádové sítě je znázorněna na obrázku 5.2. Jde o dopřednou síť s jednou vstupní vrstvou n vstupních jednotek, skrytou vrstvou obsahující h perceptronů, a lineární výstupní vrstvou o m

jednotkách. Perceptronové jednotky jsou navíc pospojovány laterálními spoji, které jdou jedním směrem, řekněme zleva doprava ve smyslu očíslování skrytých jednotek. Každý perceptron dostává jako vstupní signály i výstupy ze všech předchozích jednotek ve skryté vrstvě. Takže i -tá jednotka ve skryté vrstvě má jako obvykle n vstupů spojených se vstupními jednotkami a dále $i-1$ vstupů napojených na výstupy jednotek j , kde $j=1, \dots, i-1$. Výstupní jednotky jsou spojeny se všemi jednotkami ze skryté i vstupní vrstvy (na obrázku 5.2 nejsou pro přehlednost znázorněny spoje mezi vstupními a výstupními jednotkami).



Obr.: 5.2 Kaskádová síť (laterální spoje jsou značeny oblými šipkami)

Funkce $f : R^n \rightarrow R^m$ realizovaná kaskádovou sítí v **aktivním režimu** se díky rekurentním vztahům mezi skrytými jednotkami zapisuje jedním vzorcem poměrně nesnadno, ale samotný způsob, jakým síť počítá odezvu na předložený vstup $x \in R^n$ je jednoduchý. Jednotky ve skryté vrstvě postupně dle svého pořadí i spočtou svou výstupní hodnotu z_i podle obvyklé přechodové funkce známé z perceptronů:

$$z_i = \sigma \left(\sum_{j=0}^n w_{ij} x_j + \sum w_{i(n+j)} z_j \right) \quad \text{pro } i = 1, \dots, h, \quad (11)$$

kde w_{ij} jsou váhy, σ je aktivační funkce.

Pro každý perceptron i jsou tedy váhy příslušející výstupům předchozích jednotek zařazeny formálně na konec váhového vektoru, odpovídají vždy pozicím $n+1, \dots, n+i-1$. V další fázi výpočtu potom jednotky ve výstupní vrstvě spočtou lineární kombinace svých vstupů a aplikují přechodovou funkci:

$$y_i = \sigma \left(\sum_{j=1}^{n+h} v_{ij} z_j \right) \quad \text{pro } i = 1, \dots, m. \quad (12)$$

6. Asociativní neuronové sítě

6.1. Lineární asociativní síť

Lineární asociativní síť je příkladem modelu neuronové sítě, který se využívá jako asociativní paměť. Na rozdíl od paměti klasických počítačů, kdy klíčem k vyhledání položky v paměti je adresa, u asociativní paměti vybavení příslušné informace probíhá na základě její částečné znalosti (asociace). Například v databázových aplikacích je znalost některých položek záznamu postačující k vyhledání celého záznamu. Podobně u člověka např. černobílá fotografie přítele pomůže vybavit barvu jeho vlasů či očí, popř. jeho jméno. Rozlišujeme v zásadě dva typy asociativní paměti: auto-asociativní a heteroasociativní.

U autoasociativní paměti půjde o upřesnění či zúplnění vstupní informace, což motivačním příkladem s černobílou fotografií znamená vybavení odpovídajícího barevného obrazu. Naproti tomu u heteroasociativní paměti dochází k vybavení určité sdružené informace na základě vstupní asociace, což v uvedeném příkladem může odpovídat určení jména osoby na fotografii.

Organizační i aktivní dynamika lineární asociativní sítě je téměř identická jako u modelu MADALINE. Jediný rozdíl spočívá v tom, že lineární asociativní síť v aktivním režimu místo afinních kombinací počítá jen lineární kombinace vstupů, tj. chybí formální jednotkový vstup a odpovídající biasy jsou nulové. Formálně lze tedy funkci lineární asociativní $y(w) : R^n \rightarrow R^m$ zapsat:

$$y_j = \sum_{i=1}^n w_{ji} x_i \quad j = 1, \dots, m. \quad (13)$$

Adaptace podle Hebbova zákona:

Adaptivní dynamiku lineární asociativní sítě popíšeme v tomto odstavci obecně pro případ heteroasociativní paměti, jejímž speciálním případem je autoasociativní paměť. Jeden z možných způsobů adaptace této sítě je motivován neurofyzilogickým Hebbovým zákonem (14), který tvrdí, že změna synaptické váhy spoje mezi dvěma neurony je úměrná jejich souhlasné aktivitě, tj. součinu jejich stavů. Donald Hebb [6] tímto způsobem vysvětloval vznik podmíněných

reflexů, kdy současná aktivita (popř. pasivita) prvního neuronu odpovídající podmínce (příčině) a druhého neuronu vyvolávající reflex posiluje synaptickou vazbu spoje směrem od prvního k druhému neuronu. Obráceně opačná aktivita těchto neuronů tuto vazbu zeslabuje.

Hebbův zákon lze tedy formálně shrnout do následující adaptivní dynamiky lineární asociativní sítě. Na začátku adaptace v čase 0 jsou všechny váhy konfigurace nulové, tj. $w_{ji}^0 = 0$ ($j = 1, \dots, m, i = 1, \dots, n$). V diskrétním čase adaptace $t = 1, \dots, p$, kdy je síti předložen k -tý tréninkový vzor ($k = t$), se váhy adaptují podle Hebbova zákona:

$$w_{ji}^{(t)} = w_{ji}^{(t-1)} + d_{kj} x_{ki} \quad \begin{array}{l} j = 1, \dots, m \\ i = 1, \dots, n. \end{array} \quad (14)$$

Vzhledem k tomu, že adaptivní režim v tomto případě skočí po p krocích, kdy jsou již všechny tréninkové vzory naučeny, lze výslednou konfiguraci formálně vyjádřit jako konečný součet:


$$w_{ji} = \sum_{k=1}^p d_{kj} x_{ki} \quad \begin{array}{l} j = 1, \dots, m \\ i = 1, \dots, n. \end{array} \quad (15)$$

6.2. Hopfieldova síť

Dalším důležitým modelem neuronové sítě, který je předmětem velkého zájmu badatelů, je Hopfieldova síť. Tento model byl navržen již McCullochem a Pittsem [5]. Avšak teprve díky Hopfieldovi [13], který při analýze stability této sítě využil průhlednou analogii s fyzikální teorií magnetických materiálů, se tento model sítě stal všeobecně známým, a proto také nese jeho jméno. Hopfieldova síť se používá jako autoasociativní paměť. V současnosti existuje mnoho teoretických výsledků a variant uvedeného modelu, které se snaží zlepšit jeho vlastnosti. V další podkapitole se omezíme jen na popis základního modelu Hopfieldovy sítě.

6.2.1 Základní model

Organizační dynamika Hopfieldovy sítě specifikuje na začátku pevnou úplnou topologii cyklické sítě s n neurony, kde každý neuron v síti je spojen s každým, tj. má všechny neurony za své vstupy. Dále všechny neurony v síti jsou zároveň vstupní i výstupní. Architektura Hopfieldovy sítě je znázorněna na obrázku 6.1.



Obr.6.1: Topologie Hopfieldovy sítě

Adaptivní dynamika Hopfieldovy sítě se řídí Hebbovým zákonem (14). Požadovaná funkce sítě je opět specifikována tréninkovou množinou p vzorů (16), z nichž každý je zadán vektorem n bipolárních stavů vstupních, resp. výstupních neuronů, které v případě autoasociativní paměti splývají.

$$\tau = \{x_k | x_k = (x_{k1}, \dots, x_{kn}) \in \{-1, 1\}^n, k = 1, \dots, p\}. \quad (16)$$

Adaptivní dynamika podle Hebbova zákona probíhá v p diskrétních krocích, ve kterých jsou síti postupně předkládány tréninkové vzory, podle nichž se adaptují synaptické váhy. Výslednou konfiguraci sítě lze zapsat následujícím způsobem:

$$w_{ji} = \sum_{k=1}^p x_{kj} x_{ki} \quad 1 \leq j \neq i \leq n. \quad (17)$$

Nejprve si všimneme, že $w_{ji} = w_{ij}$ ($1 \leq i, j \leq n$), protože postavení neuronů i, j ve vzorci (17) je symetrické. Proto se někdy Hopfieldovy síti říká symetrická síť, v níž

dva opačně orientované spoje mezi dvěma neurony lze chápat jako jeden orientovaný spoj.

Aktivní dynamiku Hopfieldovy sítě si popíšeme pro případ sekvenčního synchronního výpočtu. Na začátku aktivního režimu v čase 0 jsou stavy neuronů nastaveny na vstup sítě $x = (x_1, \dots, x_n)$, tj. $y_i^{(0)} = x_i (i = 1, \dots, n)$. V diskrétním čase $t > 0$ výpočtu je aktualizován neuron j (ostatní svůj stav nemění), který je vybrán např. systematicky tak, že $t = \tau n + j$, kde τ je tzv. makroskopický čas, tj. počet period, ve kterých jsou aktualizovány všechny neurony. Nejprve je vypočten celočíselný vnitřní potenciál neuronu j :

$$\xi_j^{(t-1)} = \sum_{i=1}^n w_{ji} y_i^{(t-1)}, \quad (18)$$


Jehož znaménko určuje jeho nový bipolární stav:

$$y_j^{(t)} = \begin{cases} 1 & \xi_j^{(t-1)} > 0 \\ y_j^{(t-1)} & \xi_j^{(t-1)} = 0 \\ -1 & \xi_j^{(t-1)} < 0. \end{cases} \quad (19)$$

Výpočet (tj. aktivní režim) Hopfieldovy sítě skončí v čase t^* , když se síť nachází v tzv. stabilním stavu, tj. stavy neuronů se již nemění.

6.2.2. Energetická funkce

Jak již bylo v úvodu této podkapitoly řečeno, Hopfieldova síť má svoji přirozenou fyzikální analogii. Některé jednoduché modely magnetických materiálů ve statistické fyzice (např. spinová skla) připomínají Hopfieldovu síť. Magnetické materiály lze v těchto modelech chápat jako soubor atomických magnetů, tzv. spinů, odpovídajících v Hopfieldově síti neuronům, které jsou uspořádány do pravidelné mřížky reprezentující krystalickou strukturu těchto materiálů, jak je znázorněno na obrázku 6.2.



Obr. 6.2.: Model magnetického materiálu

Uvažujeme nejjednodušší případ atomů, kde každý spin může mít dvě možné magnetické orientace, což v Hopfieldově síti modelujeme neuronovými stavy 1a-1. Fyzikální model je dále specifikován interakcí a dynamikou spinu. Každý spin je ovlivněn okolním magnetickým polem, které je možné rozdělit na externí, které v Hopfieldově síti odpovídá vstupu, a na interní pole vytvořené ostatními spiny. Příspěvek každého atomu do okolního vnitřního pole je úměrný jeho vlastnímu spinu. Součet těchto příspěvků určuje magnetické pole ovlivňující daný spin, což odpovídá aktivní dynamice Hopfieldovy sítě. Synaptické váhy v rovnici (18) modelují vzájemné interaktivní síly spinu, které jsou ve fyzikálním modelu symetrické a mohou být různě velké, kladné nebo záporné v závislosti na makroskopických vlastnostech materiálu. Fyzikální model odpovídá asynchronní Hopfieldově síti.


K lepšímu pochopení aktivní dynamiky Hopfieldovy sítě (18), (19) byla Hopfioldem v analogii s fyzikálními ději definována tzv. energetická funkce $E(\mathbf{y})$ sítě, která každému stavu sítě $\mathbf{y} \in \{-1,1\}^n$ přiřazuje jeho potenciální energii podle kvadratické formy:

$$E_{(y)} = -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n w_{ji} y_j y_i. \quad (20)$$

Cílem adaptace Hopfieldovy sítě podle Hebbova zákona (14) je nalezení takové konfigurace, aby funkce sítě v aktivním režimu realizovala autoasociativní paměť. To znamená, že pro vstup blízký nějakému tréninkovému vzoru by výstup sítě měl odpovídat tomuto vzoru.

6.2.3. Příklad aplikace Hopfieldovy sítě

Uvedené obecné principy budeme ještě ilustrovat na příkladě využití Hopfieldovy sítě pro redukci šumu rozpoznávaných znaků, v tomto případě číslic. Obraz cifry je rozložen na matici 12 x 10 černobílých obrazových bodů, které odpovídají 120 neuronům Hopfieldovy sítě tak, že jejich stavy 1,-1 reprezentují po řadě černou a bílou barvu. Dále byly vytvořeny vzorové obrazy osmi uvažovaných číslic, které posloužily jako tréninkové vzory při adaptaci Hopfieldovy sítě podle Hebbova zákona (14). Naučené síti byl pak předložen vstup odpovídající obrazu cifry, který vznikl 25% šumem vzorového obrazu trojky. Na obrázku 6.3 můžeme sledovat průběh aktivního režimu Hopfieldovy sítě pro tento vstup monitorovaný v makroskopických časových krocích. Hopfieldova síť postupně odstraňuje z obrazu číslice šum, tj. pracuje jako autoasociativní paměť, když vybavuje původní vzorový obraz trojky, který odpovídá stabilnímu stavu sítě.



Obr. 6.3: Příklad aplikace Hopfieldovy sítě [2]

Závěr

Počet možných alternativ modelů neuronových sítí a jejich použití je poměrně velký. Mohli bychom se domnívat, že v tomto směru, už nelze očekávat další nové objevy, ale to není zdaleka jisté. Jisté je pouze to, že pohybujeme-li se v oblasti umělých neuronových sítí, rozhodně bychom neměli podceňovat jejich důležitost.

Neuronové sítě lze přirozeným způsobem použít k rozpoznávání obrazců, a to pro speciální případ – rozpoznávání psaných, resp. tištěných znaků. V tomto případě se takový obraz znaku nejprve odseparuje od okolního textu a potom se znormuje, tj. zobrazí do standardizované matice bodů. Další možnou oblastí využití neuronových sítí je řízení složitých zařízení v dynamicky se měnících podmínkách. Příkladem řídicího systému je autopilot automobilu. Jinou důležitou aplikační oblastí neuronových sítí je predikce a příp. následné rozhodování. Typickými příklady z této oblasti jsou předpověď počasí, vývoj cen akcií na burze, spotřeba elektrické energie apod.

Často zmiňovanou aplikací neuronových sítí je komprese dat. Používá se perceptronová síť, která je historicky prvním úspěšným modelem neuronové sítě. Nevýhodou je, že tento přístup je založen na pevném, předem stanoveném, kompresním poměru, daném typologií použité sítě.

Nejnámější a nejpoužívanější model neuronové sítě je vícevrstvá neuronová síť, která se používá přibližně v 80 % všech aplikací neuronových sítí. Dalším historicky důležitým modelem neuronové sítě je MADALINE, který byl navržen Widrowem a Hoffem. Základním prvkem tohoto modelu je neuron ADALINE. Tento model je téměř identický se sítí perceptronů, i když původně vychází z jiných principů.

Příkladem modelu neuronové sítě, který se využívá jako asociativní paměť je lineární asociativní síť. Na rozdíl od paměti klasických počítačů, kdy klíčem k vyhledávání položky v paměti je adresa, u asociativní paměti vybavení příslušné informace probíhá za základě její částečné znalosti (asociace). Dalším důležitým modelem je Hopfieldova síť, která se používá jako autoasociativní paměť. Tento model byl navržen již McCullochem a Pittsem. Avšak teprve díky Hopfieldovi se stal známým.

Z hlediska kvality není možno jednotlivé modely neuronu porovnávat. Každý má své přednosti a své zápory, záleží jen na tom, jaké jsou naše požadavky na použitý model.

Anotace

Tato bakalářská práce se zaměřuje na teoretické základy neuronových sítí, na popis základních modelů neuronových sítí a jejich použití v praxi. Poskytuje stručný přehled historie bádání v oblasti neurovýpočtů a objasňuje neurofyziologické motivace vedoucí k matematickému modelu neuronu a neuronové sítě. Počet možných alternativ modelů neuronových sítí a jejich použití je poměrně velký. Neuronové sítě lze použít k rozpoznávání obrazců, ke kompresi dat atd. K nejznámějším modelům neuronové sítě patří vícevrstvá neuronová síť, model MADALINE, asociativní síť a Hopfieldova síť.

In focus of this dissertation is the theoretical background of the neural networks with a description of basic models of these neural networks and their application in practice. Furthermore, this work provides a concise historical overview of the exploration on field of the neural calculations. It also clarifies neuro-physiological motivation that conducts to the mathematical model of the neuron just like the neural networks. The number of options of neural networks and ways how to apply them is high. The neural networks can be used to define figures or to compress data, and so on. Among the most familiar models of a neural network is the multilayer neural network, the model of MADALINE, the associative network or the Hopfield's network.

Seznam použité literatury

- [1] Hakl F., Holeňa M.: Úvod do teorie neuronových sítí, ČVUT, Praha, 1998, ISBN 80-01-01716-8.
- [2] Šíma J., Neruda R.: Teoretické otázky neuronových sítí, MATTFYZPRESS, Praha, 2006, ISBN 80-85863-18-9.
- [3] Šnorek M.: Neuronové sítě a neuropočítače, ČVUT, Praha, 2002, ISBN 80-01-02549-7.
- [4] Prof. Ing. Ivo Vondrák, CSc: Umělá inteligence a neuronové sítě. Ostrava: VŠB Technická univerzita Ostrava, 2002.
- [5] W.S. McCulloch and w. Pitts: A logical calculus of the ideas immanent in nervous activity. Bulletin of mathematical biophysics, 1943.
- [6] D.O. Hebb: The organization of behavior: A neuropsychological theory. Wiley, New York, 1949.
- [7] F. Rosenblatt: The perceptron: A probabilistic model for information storage and organization in the brain, Psychological review, 1958.
- [8] N. J. Nilson: Learning machines: McGraw-Hill, New York, 1965.
- [9] D.E. Rumelhart, G.E. Hinton and R. J. Williams: Learning internal representations by error propagation. In D.E. Rumelhart and J. L. McClelland, editors, parallel distributed processing: Explorations in the microstructure of cognition, volume I, MIT press, Cambridge MA, 1986.
- [10] J. F. Shepanski and S.A. Macy. Teaching artificial neural systems to drive: Manual training techniques for autonomous systems. In D.Z. Anderson, editor,

Proceedings of the neural information processing systems conference, New York, American institute of physics, 1988, 1987.

[11] Vlček K. Teorie informace a kódování, VŠB-TU Ostrava 2000.

[12] Sojka E.: Digitální zpracování a analýza obrazů, VŠB-TU Ostrava, 2000.

[13] J.J. Hopfield. Neural network and physical systems with emergent collective computational abilities. In proceeding of the National Academy of sciences, 1982.

[14] Ondřej Čítek

<http://avenue-de.net/school/komprese.pdf>

[15] Vladimír Myslík

<http://aldebaran.feld.cvut.cz/~xmyslik/www/neurasci.html>

[16] Neuronové sítě

http://nlp.fi.muni.cz/projekty/uvod_do_inference/html/aplikace/neuronsite.htm