

**ZÁPADOČESKÁ UNIVERZITA V PLZNI**  
**FAKULTA ELEKTROTECHNICKÁ**

**KATEDRA TECHNOLOGIÍ A MĚŘENÍ**

**BAKALÁŘSKÁ PRÁCE**

**Využití umělých neuronových sítí v technické diagnostice**

**vedoucí práce:**

**Ing. Tomáš Hujer**

**2012**

**autor:**

**Vojtěch Jíša**

**ZÁPADOČESKÁ UNIVERZITA V PLZNI**

**Fakulta elektrotechnická**

**Akademický rok: 2011/2012**

## **ZADÁNÍ BAKALÁŘSKÉ PRÁCE**

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Vojtěch JÍŠA**  
Osobní číslo: **E09B0371P**  
Studijní program: **B2612 Elektrotechnika a informatika**  
Studijní obor: **Komerční elektrotechnika**  
Název tématu: **Využití umělých neuronových sítí v technické diagnostice**  
Zadávající katedra: **Katedra technologií a měření**

### **Z á s a d y p r o v y p r a c o v á n í :**

1. Popište historii vzniku a vývoje umělých neuronových sítí (ANN).
2. Popište princip nejběžnějších typů ANN.
3. Uveďte příklady využití ANN v diagnostice.
4. Seznamte se s dostupnými nástroji pro tvorbu ANN a popište jejich klady a zápory.
5. Navrhněte metodiku výběru, tvorby a aplikace neuronové sítě pro oblast technické diagnostiky.


Rozsah grafických prací: **podle doporučení vedoucího**  
Rozsah pracovní zprávy: **20 - 30 stran**  
Forma zpracování bakalářské práce: **tištěná/elektronická**  
Seznam odborné literatury:


### **1. Elektronické informační zdroje**

Vedoucí bakalářské práce: **Ing. Tomáš Hujer**  
Katedra technologií a měření

Datum zadání bakalářské práce: **17. října 2011**  
Termín odevzdání bakalářské práce: **3. června 2012**

  
Doc. Ing. Jiří Hammerbauer, Ph.D.  
děkan



  
Doc. Ing. Vlastimil Skočil, CSc.  
vedoucí katedry

V Plzni dne 17. října 2011

## **Abstrakt**

Předkládaná bakalářská práce se zabývá problematikou umělých neuronových sítí. V této práci je stručně popsána také historie tohoto odvětví. Dále je v práci možné nalézt rozdíl mezi biologickým a umělým neuronem a obecné vlastnosti umělých neuronových sítí. Je zde pojednáno o praktickém využití umělých neuronových sítí, zejména pak v technické diagnostice. Na závěr jsou zmíněny softwarové možnosti v oblasti umělých neuronových sítí.

## **Klíčová slova**

Umělá neuronová síť, biologický neuron, učení sítě, diagnostika, modelování, klasifikace, predikce.

**Abstract**

This bachelor's thesis deals with the issues of artificial neural networks. In this essay is dealt with the historical background of this field. The difference between a biological and artificial neuron is described as well as the basic characteristics of the artificial neural networks. This essay also sums up the practical applications of the artificial neural networks, mainly in the field of technical diagnostics. At last you can find a brief description of several software related to the field.

**Key words**

Artificial neural network, biological neuron, learning of the network, diagnostics, modeling, classification, prediction,

## **Prohlášení**

Předkládám tímto k posouzení a obhajobě bakalářskou práci, zpracovanou na závěr studia na Fakultě elektrotechnické Západočeské univerzity v Plzni.

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně, s použitím odborné literatury a pramenů uvedených v seznamu, který je součástí této diplomové práce.

Dále prohlašuji, že veškerý software, použitý při řešení této bakalářské/diplomové práce, je legální.

V Plzni dne 7.6.2012

Vojtěch Jíša

## **Poděkování**

Tímto bych rád poděkoval vedoucímu diplomové práce Ing. Tomáši Hujerovi za cenné profesionální rady, připomínky a metodické vedení práce.

## Obsah

|   |           |
|---|-----------|
| <b>OBSAH .....</b>  | <b>8</b>  |
| <b>ÚVOD.....</b>  | <b>9</b>  |
| <b>1 ZÁKLADY PROBLEMATIKY UMĚLÝCH NEURONOVÝCH SÍTÍ .....</b>      | <b>10</b> |
| 1.1 HISTORIE PROBLEMATIKY UMĚLÝCH NEURONOVÝCH SÍTÍ .....          | 10        |
| 1.2 SOUČASNÝ STAV VÝZKUMU.....                                    | 13        |
| <b>2 POPIS STRUKTURY .....</b>                                    | <b>15</b> |
| 2.1 BIOLOGICKÝ MODEL NEURONU.....                                 | 15        |
| 2.2 MATEMATICKÝ MODEL NEURONU .....                               | 16        |
| 2.2.1 <i>Synaptické operace</i> .....                             | 16        |
| 2.2.2 <i>Somatické operace</i> .....                              | 18        |
| 2.2.3 <i>Příklady přenosové funkce</i> .....                      | 20        |
| 2.3 MODEL UMĚLÉ NEURONOVÉ SÍTĚ .....                              | 22        |
| 2.3.1 <i>Topologie umělé neuronové sítě</i> .....                 | 23        |
| 2.3.2 <i>Vrstvená neuronová síť</i> .....                         | 23        |
| 2.3.3 <i>Metody učení umělé neuronové sítě</i> .....              | 24        |
| 2.3.3.1 <i>Učení bez učitele</i> .....                            | 25        |
| 2.3.3.2 <i>Učení s učitelem</i> .....                             | 25        |
| <b>3 APLIKACE UMĚLÝCH NEURONOVÝCH SÍTÍ.....</b>                   | <b>26</b> |
| 3.1 UMĚLÉ NEURONOVÉ SÍTĚ V TECHNICKÉ DIAGNOSTICE.....             | 27        |
| 3.1.1 <i>Aktuální diagnostika</i> .....                           | 27        |
| 3.1.2 <i>Modelování umělými neuronovými sítěmi</i> .....          | 29        |
| 3.1.3 <i>Aktuální klasifikace neuronovými sítěmi</i> .....        | 31        |
| 3.1.4 <i>Predikce neuronovými sítěmi</i> .....                    | 32        |
| 3.1.5 <i>Prognostická klasifikace neuronovými sítěmi</i> .....    | 32        |
| <b>4 SOFTWAREVÁ PROSTŘEDÍ PRO PRÁCI S NEURONOVÝMI SÍTĚMI.....</b> | <b>33</b> |
| 4.1 STATISTICA AUTOMATIZOVANÉ NEURONOVÉ SÍTĚ .....                | 33        |
| 4.1.1 <i>Implementace neuronových sítí</i> .....                  | 33        |
| 4.1.2 <i>Automatické vyhledávání sítě</i> .....                   | 34        |
| 4.1.3 <i>Trénování sítě</i> .....                                 | 34        |
| 4.2 NETVISUALISER .....   | 35        |
| 4.2.1 <i>O programu</i> .....                                     | 35        |
| 4.3 JINÁ SOFTWAREVÁ PROSTŘEDÍ .....                               | 36        |
| <b>ZÁVĚR .....</b>  | <b>37</b> |
| <b>POUŽITÁ LITERATURA.....</b>                                    | <b>38</b> |



## Úvod

Výpočetní technika a její vývoj se nezastavitelným tempem rozrůstá. Takřka v každém oboru je snaha o automatizaci co největšího množství úkonů a tím zrychlit a zefektivnit danou činnost. S přibývajícím časem a novými znalostmi rostla i složitost počítačových systémů a byly vymyšleny stále náročnější a důmyslnější algoritmy pro řešení daných úloh.

V poslední letech opět vzrostl zájem o umělé neuronové sítě, zjednodušeně řečeno matematické modely nervových soustav živých organismů. Na jedné straně výzkumu jsou odborníci, kteří se snaží pochopit a popsat způsob, jakým např. lidský mozek funguje. Na straně druhé jsou pak inženýři a vědci, kteří se snaží, na základě neurofyziologických poznatků, provést umělou realizaci dané nervové soustavy a co nejvěrněji napodobit její funkce a možnosti.

Neuronová síť se skládá z neuronů – základních funkčních jednotek, které jsou navzájem různě propojeny. Neuron je pak definován určitým množstvím vstupních spojů (dendritů), výstupem (axon) a svoji přenosovou funkcí. Každý vstup má potom svou vlastní vahovou hodnotu, která zajišťuje, jak moc daný spoj ovlivní konečný výstup neuronu. Vlastnosti sítě pak závisí na topologii (architektuře) sítě, ale také na počtu a nastavení jejích neuronů. Jednotlivé praktické aplikace pak využívají různých typů a vlastností jednotlivých neuronových sítí.

Tato práce se zabývá problematikou umělých neuronových sítí. V první kapitole je stručně popsán historický podklad dané problematiky u nás a ve světě. Dále jsou pak popsány rozdíly mezi umělým a biologickým neuronem, obecné charakteristiky umělých neuronových sítí a také základní metody učení příslušných sítí. Třetí kapitola se pak zabývá praktickým využitím umělých neuronových sítí, zejména pak v technické diagnostice. Na závěr je pojednáno o některých softwarových prostředích, které se dají v oblasti umělých neuronových sítí používat.

# 1 Základy problematiky umělých neuronových sítí

## 1.1 Historie problematiky umělých neuronových sítí

Přes veškerou modernost a progresivní vývoj informační technologie umělých neuronových sítí je její historie již velice dlouhá. Při sledování historie lidstva narazíme na snahu dobrat se alespoň k základnímu poznání o tom, jak a čím vlastně lidé a ostatní živé organismy myslí a co je podstatou myšlení, bezpochyby již v starověkých antických dobách ve spisech tehdejších filozofů, kteří si, pro inteligentně smýšlejícího člověka, kladli tyto základní otázky a snažili se přijít na vhodné odpovědi. Odpovědi byly však citelně poznamenány možnostmi doby a dosavadními znalostmi. Již ze 17. století př. Kr. pocházejí nejstarší známé záznamy o popisu poznatků o mozku. Na nalezeném staroegyptském papyrovém svitku je několikrát použito slovo „ys“ (v překladu znamenající „mozek“) při záznamu operace dvou Egyptanů. Tento záznam pojednává o symptomech, diagnóze a další prognóze této operace. Tento nálezn dokládá, že znalosti o mozku ve starověkém Egyptě musely být na vysoké úrovni. [1]

Základními a nejspíše i hlavními důvody, proč si lidé již od pradávna kladli otázky ohledně podstaty myšlení a později i struktury mozku a jeho funkci, byli a jsou poměrně patrné: myšlení, potažmo jeho úroveň, je to základní, čím se člověk liší od zvířat. Myšlení je nejvyšší známá funkce lidského informačního systému, který je velmi důležitým nástrojem pro zajišťování naší existence. Existence a funkce informačního systému je nutná, ale ne postačující podmínkou existence, přežití a rozvoje jakékoliv existující soustavy. Je nutné, aby patřičná soustava byla schopna informace daným informačním systémem dodané, zpracované a uchované efektivně využívat. Porušení těchto teorémů dříve nebo později vede k zániku příslušné soustavy. Pochopení mozku a myšlení, jakožto našeho informačního systému, je proto pro lidstvo velmi důležitý. Nicméně i přes veškerý pokrok a znalosti v této problematice, jsme stále na samém začátku. [1]

Úroveň odpovědí na otázky ohledně myšlení se pochopitelně měnila s vývojem dějin a úrovní vzdělání a znalostí. Finální odpovědi i navzdory obrovskému celosvětovému úsilí v této problematice ovšem stále neznáme a s největší pravděpodobností ani ještě dlouho nebudeme. [2]

V počátečních obdobích snah o pochopení a vysvětlení podstaty myšlení se uplatňoval hlavně přístup „zevnějšku“ – o podstatě se dělaly závěry na základě vnějšího projevu. Až pozdější rozvoj fyziologie, neurologie a dalších příbuzných odvětví umožnil bližší poznání

struktury mozku a pochopení jeho základních principů. V dnešní době je typické kombinování obou zmiňovaných přístupů. Přístup „zvnitřku“, kde jsou základem elementy uvažovaného systému a zákonitosti jejich interakce, byl výrazně prohlouben v druhé polovině 19. století a první polovině století minulého v souvislosti s výrazným rozvojem právě zmiňovaných vědních oborů a věd o buňkách jako elementech organizmů. Velký podíl v tomto rozvoji měly práce našeho Jana Evangelisty Purkyně a později také španělský držitel Nobelovy ceny za fyziologii a medicínu Santiago Ramón y Cajal. Později se k nim přidružil další významný přístup – tvorba matematických modelů dané problematiky. Významnými průkopníky v této oblasti byli Američané Warren Sturgis McCulloch a jeho student Walter Pitts, kteří jsou autory prvního reálně použitelného matematického modelu neuronu – publikováno v roce 1943 (McCulloch ostatně předpověděl už v roce 1921, že budou v budoucnu uměle napodobovány neuronové sítě pro zpracovávání informací). Přestože byl jejich model neuronu v dalších letech hojně modifikován, doplňován a vylepšován, je stále základem převážné většiny umělých neuronových sítí i dnes. [1] [3] [8]

Konec druhé světové války přinesl velký nástup a rozvoj problematiky umělých neuronových sítí. V elektronice v té době vrcholila tzv. elektronková éra a pro nástup polovodičové éry se jevíly umělé neuronové sítě jako jedno z možných řešení problémů, na které narážela elektronková technologie. V té době sice ještě nebyly známé základní teorie neuronových sítí, ale k řadě překvapivým výsledkům postačily i jednoduché umělé struktury sítí vycházející ze základních modelů McCullochova výzkumu. Jednalo se převážně o jednoduché jednovrstvé sítě tzv. perceptronového typu s lineárními přenosovými funkcemi.

V roce 1949 publikoval Donald Hebb dílo „Organization of Behavior“ („Struktura chování“), kde pojednává o poznatcích o zákonu učení, pomocí kterého osvětlil postupy učení sítí neuronů a na základě toho bylo možné přistoupit ke konstrukci učících algoritmů, prakticky použitelných pro řešení konkrétních úloh jednoduchými vrstevnatými neuronovými sítěmi. Profesor Bernard Widrow z Kalifornské univerzity Stanford byl jedním z protagonistů těchto neuronových sítí. Widrowem navržené systémy ADALINE a později MADALINE našly ve své době hojné uplatnění v civilní i vojenské sféře a v některých aplikacích se využívají dodnes. [3] [8]

Na základě těchto poznatků se umělým neuronovým sítím začala otevírat velice slibná budoucnost, dokonce se začalo uvažovat o napodobení lidského mozku a smýšlení. V dalších letech v tomto oboru pracovalo mnoho významných jmen. Frank Rosenblatt položil základy pro učící algoritmus pro vrstvené neuronové sítě s dopředným přenosem signálu mezi vstupem a výstupem, z kterého pak Widrow a Hoff odvodili modifikaci, dnes známou jako

Widrowův a Hoffův zákon. [2]

U nás v této době na problematice umělých neuronových sítí pracovala malá skupina výzkumníků z Elektrotechnické fakulty ČVUT okolo Ing. Hiršla. Ohledně otázek funkce mozku se zabýval tým z tehdejší ČSAV spolu s Dr. Weissem. [1]

Zvrat přišel v druhé polovině šedesátých let, když v roce 1969 publikovali Minsky a Papert svou knihu Receptor, kde popsali teoretické hranice možností jednovrstvé neuronové sítě – perceptronu. Matematicky dokázali, že touto neuronovou sítí nelze realizovat ani elementární logickou funkci XOR. Nicméně jejich subjektivní podání a následná kampaň vědců Minsky a Papert vedla poté k tomu, že došlo k útlumu zájmu veřejnosti a s tím i sponzorů. Této skutečnosti samozřejmě pomohly i jiné faktory, jako byl např. rozvoj mikroprocesorů aj. Později vycházely na povrch různé důkazy o tom, že Minsky a Papert nepostupovali při svých tvrzeních proti umělým neuronovým sítím čistě vědecky, objektivně a nestranně, ale že naopak byli silně ovlivněni svými vlastními ekonomickými zájmy. [2] [3]

Do počátku osmdesátých let pak upadly umělé neuronové sítě takřka v zapomnění. Na vzdory jejich předchozím úspěchům se téměř přestaly využívat a jejich vývoj se prakticky zastavil. Přesto se však našli tací (J.J Hopfield, D.E. Rumelhart, T. Kohonen aj.), kteří i v této, pro vývoj umělých neuronových sítí, nepříznivé době pokračovali ve výzkumu a získali mnoho cenných převážně teoretických poznatků. Nicméně problematika umělých neuronových sítí i přes tyto cenné poznatky nenacházela v tehdejší nepříznivé atmosféře uplatnění v informačních technologiích. Značný podíl na tom měli již zmiňovaný Minsky a Papert, kteří nesprávně interpretovali důkaz o nemožnosti napodobení logického bloku XOR jednoduchým perceptronem. To sice platí pro jeden perceptron, nicméně síť tří perceptronů již tento tuto funkci simulovat umí. Minsky a Papert svůj důkaz zobecnili celkově pro neuronové sítě, což mělo za následek mnohaleté zpoždění celosvětového vývoje umělých neuronových sítí. Tato záležitost je dobrým ponaučením, jak i jedna jediná práce může být ve vědě „nebezpečná“, i přes fakt, že ji sepíše jinak renomovaný odborník. [1] [3]



Obr. 1.1 Marvin Minsky a Seymour Papert, 1971 (převzato z [4])

Nicméně i vědní oblast, kterou právě Minsky prosazoval oproti umělým neuronovým sítím – „umělá inteligence“, potkal podobný osud. Umělé inteligenci se v té době velice věřilo a ještě více tomu pomohlo vyhlášení prestižního japonského programu – počítače páté generace. Navzdory velké euforii se výsledky výrazně neshodovaly s předpoklady. Sled dosavadních událostí pak roku 1983 přiměl vedoucího vědeckého manažera americké výzkumné instituce DARPA, pana Iru Skurnika, k přehodnocení svého stanoviska ohledně problematiky umělých neuronových sítí a rozhodl se znovu vložit finanční prostředky do jejich výzkumu. Díky této finanční injekci a nepřetržitému teoretickému vývoji, hlavně v centrech okolo MIT v Bostonu a Stanfordovy univerzity u San Franciska, bylo možné přejít od teoretických poznatků k praktickému využití. Pokrok byl skutečně velice rychlý a v příštích letech pak DARPA investovala mnohanásobky onoho původního finančního obnosu. DARPA následovali další velcí sponzoři výzkumu a výsledkem byl velmi prudký nárůst zájmu o umělé neuronové sítě. [1] [2]

Z tohoto stručného shrnutí je patrné, že historie umělých neuronových sítí a funkčních systémů organismů obecně byla velmi dramatická a můžeme věřit, že k výrazným objevům v této oblasti jistě ještě dojde.

## 1.2 Současný stav výzkumu

Po celém světě je problematika umělých neuronových sítí naplní mnoha výzkumných projektů na vědeckých a vysokoškolských pracovištích. Neuronové sítě dnes již nejsou zájmem pouze vědeckých pracovníků, ale i mnoha „běžných“ uživatelů z mnoha různých

oborů. Stávající výzkum se zaměřuje především na rozvoj již velmi podrobně probádané teoretické stránky této problematiky, stávajících učících algoritmů a modifikací pro snížení hardwarových nároků. Ačkoliv v oblasti umělých neuronových sítí figurují téměř všechny státy, kde se vyskytuje nějaká univerzita (zejména technická), tak se dá mluvit o jakýchsi centrech výzkumu v této oblasti. Řeč je zejména o předních výzkumných centrech na amerických a japonských univerzitách, ale i o všech významných univerzitách v Evropě. [3]

V České republice se tato oblast netěší velkého zájmu. Průkopníky v problematice umělých neuronových sítí byli u nás hlavně prof. Ing. Zdeněk Kotek, DrSc. z Elektrotechnické fakulty ČVUT v Praze a prof. Ing. Mirko Novák, DrSc. z Ústavu informatiky AV ČR v Praze. Touto problematikou se dnes zabývají hlavně výzkumná centra na technických univerzitách a také dále Ústav informatiky AV ČR. Mnoho aplikací u nás i ve světě je cíleno pro biomedicínu. Finanční dotace putují do projektů ohledně jak teoretického výzkumu, tak i vývoje aplikací umělých neuronových sítí. [1]


V roce 1988 byla založena INNS (International Neural Network Society), která je dodnes „mateřskou“ společností v neuronové komunitě. Každoročně jsou pořádány mezinárodní konference zabývající se touto tematikou, mezi největší patří např. IJCNN – International Joint Conference on Neural Networks, ESANN – European Symposium on Artificial Neural Networks a mnoho dalších. Kromě knižní literatury jsou publikovány i specializované časopisy, jmenovitě např. Neural Networks (oficiální časopis společnosti INNS), Neural Network World a další. [3]

## 2 Popis struktury

### 2.1 Biologický model neuronu

Nervová buňka, nebo-li neuron, je základní stavební jednotkou celé nervové soustavy. Tato buňka má za úkol zpracování, uchování a přenos informací. Základní stavba neuronu je tělo a četné, rozvětvené výběžky. Neurony jsou soustředěny zejména v centrální nervové soustavě (mozek a mícha) a v jejím blízkém okolí. V lidském mozku se nachází kolem 100 miliard neuronů. [1]

Neuron se skládá ze tří základních částí: tělo – soma, výstupy – axony a vstupy – dendrity. Místo styku axonů a dendritů sousedních neuronu se nazývá synapse. Počet synapsí je v době narození minimální a vznik synapsí hraje velice důležitou roli ve vývoji mozku. Jeden jediný neuron je schopen vytvořit až 15 000 synapsí. Vzájemným propojováním neuronů prostřednictvím synapsí dochází k vytváření husté nervové sítě. Je třeba říci, že pokud nejsou synapse opakovaně využívány, tak dochází k jejich zániku. Signály přenášené mezi neurony jsou elektrické impulsy, jejichž přenos je ovlivňován chemickými látkami v synapsích. Tyto chemické látky fungují buď jako excitátory (budící signály) – neuron generuje impuls, a nebo jako inhibitory (tlumící signály) – snížení schopnosti následujícího neuronu generovat impuls. Aktivace neuronu nastává v případě, že hodnota budících signálů překročí prahovou hranici tlumících signálů. [5]

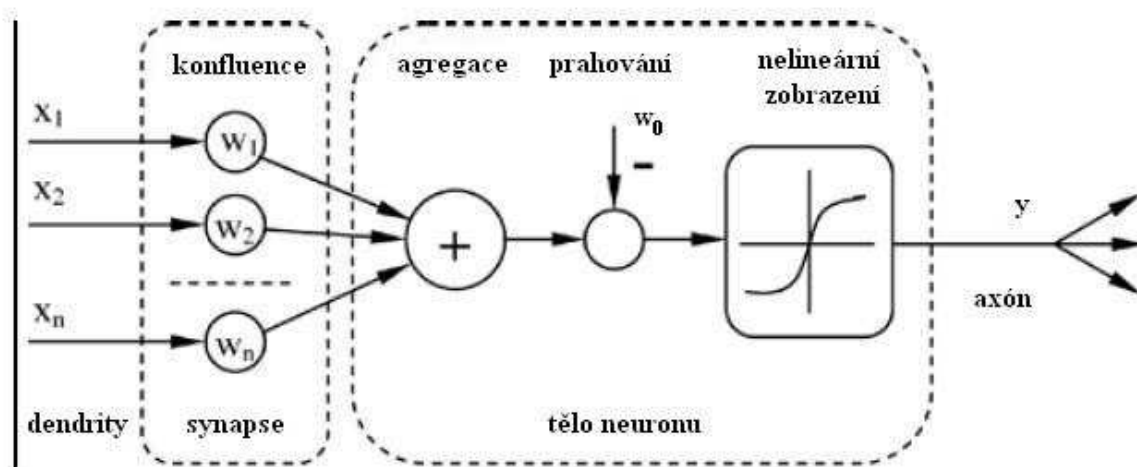


Obr. 2.1 Biologický neuron (převzato z [6])

## 2.2 Matematický model neuronu

Základní stavební jednotkou umělých neuronových sítí je právě matematický model neuronu. Složitost a využití matematické funkce samotného modelu se liší v závislosti na použití v praktických aplikacích. V praxi má největší význam tzv. formální model (také označován jako základní), jehož původní podobu popsali již McCulloch a Pitts v roce 1943. Též se můžeme setkat s označením McCulloch-Pittsův model neuronu. [1] [3] [19]

Analogii mezi umělým a matematickým modelem neuronu představuje například obr. 2.2.



Obr. 2.2 Neuron jako matematický procesor (převzato z [1])

**vstupy**  $x_1, x_2, \dots, x_n$  - představují dendrity

**váhy**  $w_1, w_2, \dots, w_n$  - představují synapse

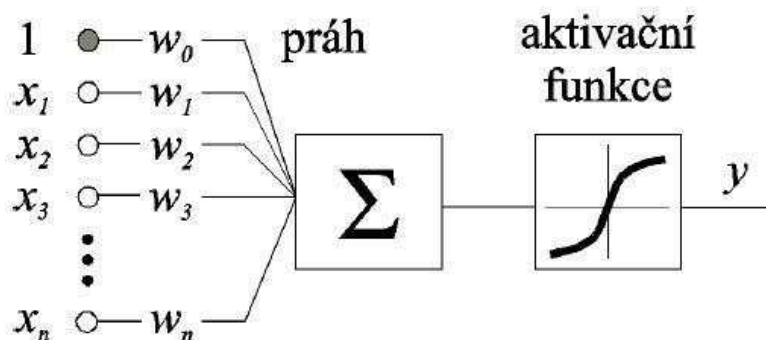
**výstup**  $y$  - představuje axón

### 2.2.1 Synaptické operace

Neuron je matematický procesor, do kterého vstupuje  $n$ -rozměrný vektor vstupního signálu a výstupem je skalární signál  $y$ . Každý model neuronu se skládá ze 2 částí, kterými jsou:

- **obvodová funkce OF** (*net function*) – tato funkce určuje, jakým způsobem bude probíhat kombinace vstupních parametrů uvnitř neuronu
- **aktivační funkce AF** (*activation function*) – přenosová funkce, která určuje, jakým způsobem budou transformovány vstupy na výstup neuronu [3]





Obr. 2.3 McCulloch-Pittsův model (převzato z [7])

Každý umělý neuron obsahuje určitý počet vstupů  $x$  a jediný výstup  $y$ . Tyto výstupy se pak dají libovolně kopírovat do požadovaného množství následujících neuronů. Vstupy sbíhající do neuronu představují buď výstupy jiných neuronů a nebo podněty ze svého okolí. Po každém takovémto vstupu přichází v daném čase informace v podobě reálného čísla. Jedná se o různé příznaky, které jsou vyjádřeny číselnou hodnotou. Máme-li na mysli vstupní informaci z okolního světa, bude celý vektor  $x = [x_1, \dots, x_n]$  charakterizovat jistý pozorovaný jev. Tyto příznaky může reprezentovat např. teplota, tlak, barva, rozměr, booleovské hodnoty (hodnoty ano, ne) a další. Každý spoj vedoucí do neuronu je navíc spojen s dalším reálným číslem  $w_i$ , který udává tzv. synaptickou váhu (např. důležitost) tohoto spoje, a každý neuron obdařen **prahem**  $\theta$ . [2] Synaptické váhy mohou nabývat i záporných hodnot, což vyjadřuje jejich inhibiční charakter. Zvážená suma vstupních hodnot představuje *vnitřní potenciál* neuronu. [8]

$$\xi = \sum_{i=1}^n w_i \cdot x_i \quad (2.1)$$

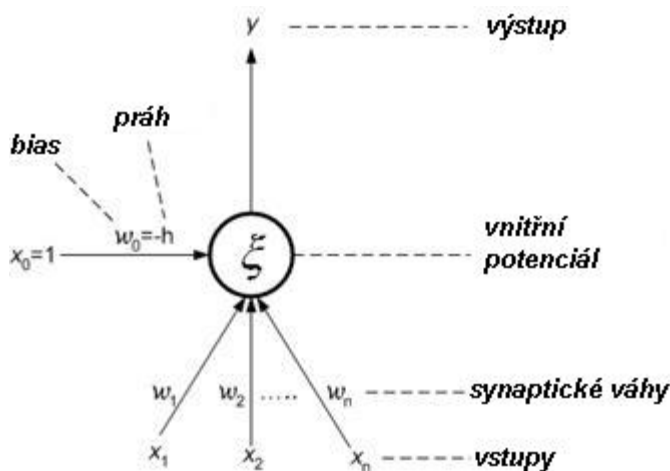
Poté co vnitřní potenciál dosáhne prahové hodnoty  $h$ , tak je indukován výstup neuronu modelující elektrický impuls axonu. Nelineární nárůst výstupní hodnoty při dosažení hodnoty prahové je dán *přenosovou funkcí*  $\sigma$ . Úplně nejjednodušší přenosovou funkcí je tzv. ostrá nelinearita, která nabývá hodnot: [8]

$$\begin{aligned} \sigma(\xi) &= 1 \text{ pro } \xi \geq h \\ \sigma(\xi) &= 0 \text{ pro } \xi < h \end{aligned} \quad (2.2)$$

Formální úpravou můžeme dosáhnout toho, že přenosová funkce  $\sigma$  bude mít nulový práh a vlastní práh neuronu se záporným znaménkem lze považovat za váhu, tzv. *bias*  $w_0 = -h$  dalšího formálního vstupu  $x_0 = 1$ , viz obr. 2.3.

Potom je funkce neuronu udávána vztahem: [8]

$$\begin{aligned} \sigma(\xi) &= 1 \text{ pro } \xi \geq 0 \\ \sigma(\xi) &= 0 \text{ pro } \xi < 0 \end{aligned} \quad \text{kde} \quad \xi = \sum_{i=0}^n w_i \cdot x_i \quad (2.3)$$



Obr. 2.3 Formální model neuronu (převzato z [9])

Jednodušeji řečeno je prahová hodnota jistá hranice, kterou musí signál nutně překročit, aby ho neuron propustil a mohl se šířit dál neuronovou sítí. Aktivitu neuronu právě určuje zmiňovaná hodnota **prahu**  $\theta$ . V umělých neuronech se pak práh často používá k posouvání signálu při vstupu do aktivační funkce. V tomto případě se prahová hodnota podílí na výstupu neuronu. Při takovém případě je dobré volit práh neuronu jak +1 resp. -1 ( $x_0$ ) násobek synaptické váhy  $w_0$ . Číslice  $x_0$  představují smyšlený vstup, který má konstantní hodnotu v závislosti na směru signálu. [10]

### 2.2.2 Somatické operace

Přepíšeme-li z kapitoly 2.2.1 operaci konfluence do tvaru:

$$z_i(t) = x_i(t) \cdot w_i(t), i = \langle 1; n \rangle \quad (2.4)$$

Pak první operací je agregace dendritických vstupních signálů  $z_i(t), i = \langle 1; n \rangle$ , která zobrazí vektor  $z(t) \in R^n$  na skalár  $u(t) \in R^1$ . Zavedením obecný agregační operátor  $G$  a dostáváme: [1]

$$\begin{aligned} u(t) &= G_{i=1}^n z_i(t) \\ \text{nebo} \\ u(t) &= G_{i=1}^n x_i(t) \cdot w_i(t) \end{aligned} \quad (2.5)$$

Pro náš základní model neuronu lze agregační operace zjednodušit. Operátor G můžeme nahradit sumací čímž dostaneme: [8]

$$u(t) = \sum_{i=1}^n z_i(t)$$

nebo

$$u(t) = \sum_{i=1}^n x_i(t) \cdot w_i(t) \tag{2.6}$$

Po této operaci následuje operace nelineárního zobrazení a prahování. Následující rovnicí lze obecně popsat tyto operace:[1]

$$y(t) = F[u(t), w_0] \tag{2.7}$$

V rovnici 2.7 F vyjadřuje přenosovou funkci a  $w_0$  prahovou hodnotu. V případě, že hodnota  $u(t)$  nepřekročí hodnotu  $w_0$  pak je na výstupu signál, který odpovídá pasivnímu stavu neuronu. Při překročení prahové hodnoty pak výstupní signál s rostoucí hodnotou  $u(t)$  monotónně roste až do saturované hodnoty. Hodnota pasivního a saturovaného stavu je dána oborem hodnot funkce F. Rovnici 2.7 je po zavedení pomocné veličiny  $v(t) = u(t) - w_0$  dále možné zjednodušit do tvaru:[1] [8] [19]

$$y(t) = F[v(t)] \tag{2.8}$$

Jako příklad je vhodné uvést jednu z nejpoužívanějších nelineárních funkcí tzv. *sigmoidní* funkci, jejíž název je odvozen od jejího tvaru, který má tvar písmene S. Tato funkce může být dána vztahem: [3] [8] [19]


$$y[v(t)] = X[v(t)] = \frac{1}{1 + e^{-v(t)}} \tag{2.9}$$

V následující tabulce jsou shrnuty jednotlivé matematické operace vykonávané *základním modelem neuronu*.


|                    |                      |                                  |
|--------------------|----------------------|----------------------------------|
| Synaptické operace | konfluence           | $z_i(t) = x_i(t) \cdot w_i(t)$   |
| Somatické operace  | agregace             | $u(t) = \sum_{i=1}^n z_i(t)$     |
|                    | prahování            | $v(t) = u(t) - w_0$              |
|                    | nelineární zobrazení | $y(t) = \frac{1}{1 + e^{-v(t)}}$ |

### 2.2.3 Příklady přenosové funkce


a) sigmoida - předpis funkce:  $y(t) = \frac{1}{1+e^{-v(t)}}$



b) hyperbolický tangens - předpis funkce:  $y(t) = \tanh v(t)$




c) lineární funkce - předpis funkce:  $y(t) = v(t)$



d) skoková funkce bipolární – předpis funkce:

$$y(t) = \begin{cases} -1 & \text{pro } v(t) < 0 \\ 0 & \text{pro } v(t) = 0 \\ 1 & \text{pro } v(t) > 0 \end{cases}$$



### 2.3 Model umělé neuronové sítě

Snahou umělých neuronových sítí je co nejlépe simulovat chování sítí biologických. Podobně jako biologickou síť tvoří obrovské množství vzájemně propojených biologických neuronů, tak i síť umělá musí být složena z množství neuronů umělých. Ačkoliv je výkonnost dnešních počítačů velice kvalitní, stále představuje značný problém ve snaze nahradit miliardy biologických neuronů těmi umělými. Mozek dokáže zpracovávat daleko větší objemy dat, i přestože má nižší rychlost přenosu informací. Nutností tedy je hledat optimální řešení, kompenzující nedostačující rychlost počítačů, ale které by přesto nacházelo požadovaný výsledek s co nejmenší chybou. Biologická síť člověka řeší v reálném čase daleko větší oblast informací, např. myšlení, koordinace pohybů, krevní oběh, funkce orgánů aj. V požadavcích na umělé neuronové sítě tedy volíme menší pole působení. [10][11]

Jedna z uváděných definic pojmu *neuronová síť* může být např.: „**Neuronová síť je paralelní distribuovaný systém výkonných prvků modelujících biologické neurony, účelně uspořádaný tak, aby byl schopen požadovaného zpracování informací.**“ (cit. [1])

Podobně jako jsou spojeny synaptickými spoji axon a dendrity jednotlivých neuronů v biologické síti, jsou i umělé neuronu propojeny mezi sebou v sítích biologických. Propojení a počet neuronů v dané neuronové síti určuje tzv. topologii (architekturu, strukturu, stavbu) této neuronové sítě. V neuronové síti rozlišujeme z hlediska funkce neurony na *vstupní*, *pracovní* a *výstupní*. Analogicky odpovídají vstupní neurony receptorům, výstupní neurony efektorům a pracovní neurony mezi nimi tvoří příslušné cesty pro šíření vzruchu. [8]

Pokud je neuronová síť brána jako orientovaný graf pak:

- **Výkonné prvky** představují uzly grafu a jejich charakteristika je představena konkrétním modelem neuronu.
- **Spoje** reprezentují hrany grafu, které pracují jako jednosměrná cesta pro šíření signálu
- Každý výkonný prvek může mít libovolný počet **vstupních spojů** a stejně tak i **výstupních spojů**. Nicméně počet výstupních spojů nemá žádný vliv na hodnotu signálu.
- Každý výkonný prvek má také svoji vlastní **lokální paměť**, kterou představuje např. prahová hodnota, resp.  $w_0$ .
- Každý výkonný prvek je také dán jistou **přenosovou funkcí**, tvořící výstupní signál. [1]

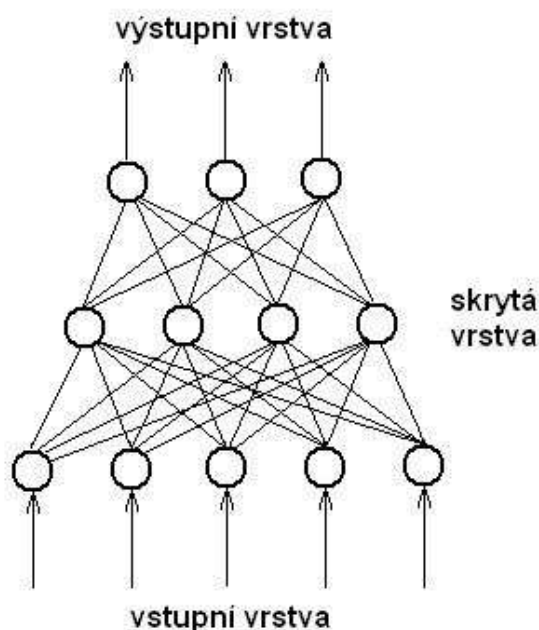
### 2.3.1 Topologie umělé neuronové sítě

Pod pojmem topologie si též můžeme představit např. struktura, stavba, uspořádání apod. V praxi se nejčastěji využívá topologie vrstvená. Jiným druhem topologie může být tzv. mapa, kde je rozložení neuronů mřížkové. [10] Rozdělení sítí můžeme provádět také např. podle průchodu informací neuronovou sítí na *dopředné (acyklické)* a *rekurentní (cyklické)* sítě, nebo podle hodnot parametrů na *statické* a *dynamické* sítě. [12]

### 2.3.2 Vrstvená neuronová síť

Vrstvené neuronové sítě s homogenními vrstvami se dělí na skupiny výkonných prvků, kde mohou mít všechny výkonné prvky stejnou přenosovou funkci, případně i jiné parametry. Tyto skupiny se označují pojmem *vrstvy*. Opakem sítí s homogenními vrstvami jsou sítě s vrstvami heterogenními, kde se mohou lišit jak přenosové funkce a jiné parametry jednotlivých prvků, ale i druhy modelů výkonných prvků samotných. [1]

Podobně jako jsem v kapitole 2.3 rozdělil neurony z hlediska jejich funkce, tak se i vrstvy ve vrstvené síti se dělí na jednu vstupní vrstvu,  $n$  skrytých vrstev a jednu vrstvu výstupní, kde každá vrstva může mít různý počet neuronů. V případě že síť se skládá pouze ze vstupní a výstupní vrstvy (tzn.  $n = 0$ ), pak takovou síť nazýváme jako dvouvrstvou. V různých publikacích se lze setkat s různým označením pro počet vrstev dané sítě, já zde budu používat označení „ $x$ -vrstvá síť“ podle vzorce  $x = n + \text{vstupní} + \text{výstupní vrstva}$ . [13] Na obrázku 2.4 můžete vidět příklad třívrstvé sítě.



Obr. 2.4 Příklad třívrstvé neuronové sítě 5-4-3 [14]

### 2.3.3 Metody učení umělé neuronové sítě

Požadavkem na každou neuronovou síť, která má řešit určitou situaci, je správné nastavení tak, aby vložená vstupní data byla co nejpřesněji přeměněna na požadované výstupní hodnoty. Tohoto výsledku se dá docílit zejména správným nastavováním vah jednotlivých spojů, protože podobně jako jsou zkušenosti u biologických neuronů uloženy v synapsích, jsou tedy v neuronech umělých uloženy v jejich matematickém ekvivalentu – vahách. [15]

Metody učení pak rozlišujeme na dvě základní skupiny:

- učení bez učitele
- učení s učitelem

Naučit síť správně řešit danou situaci vyžaduje nalezení správného nastavení všech váhových a prahových hodnot všech neuronů v síti. Hodnoty vah tedy získáváme v průběhu tréninku dané sítě. Nastavování vah, nebo-li výukový zákon, probíhá v tzv. adaptivním (učícím) režimu (změna konfigurace). Po úspěšném dokončení adaptivního režimu přechází síť do tzv. aktivního (vybavovacího) režimu (změna stavu). [10][16] Celkovou dynamiku neuronové sítě pak ještě doplňuje režim organizační (změna topologie). I v tomto rozdělení pozorujeme prozatím nereálné dosažení stejné výkonnosti jako u biologických sítí, kde příslušné změny probíhají současně, ale implementace je tímto výrazně zjednodušena. Obvykle jsou tyto dynamiky neuronové sítě určeny určitým počátečním stavem a pravidlem, které určuje vývoj daného chování sítě v čase (změny stavu, konfigurace a topologie). [17][19]

Teoreticky je možné, aby se neuronová síť učila tím, že [17]:

- rozvíjí nová spojení
- ruší existující spojení
- mění váhy spojení
- mění prahové hodnoty neuronů
- obměňuje jednu nebo více ze tří funkcí neuronu
- vznikají nové neurony
- zanikají existující neurony

V další kapitole stručně popíši některé základní metody učení.



### 2.3.3.1 Učení bez učitele

Této metodě se také říká samoorganizace. V tomto typu učení se síť snaží identifikovat podobné vzory těm, které jsou síti předkládány, a poté je zařadit do podobné kategorie. [17] Primární rozdíl mezi tímto způsobem učení a učením s učitelem (2.4.2) je ten, že je zde před trénováním neznámý výstup. Při obdržení množiny podnětů na vstupu si je daná síť sama urovná – rozdělí do kategorií podle podobnosti. Rozlišujeme zde paměť na krátkodobou (STM) a dlouhodobou (LTM). STM tvoří neustálé krátkodobé změny stavů podnětů a LTM naopak nastavení synaptických vah, které se z krátkodobého hlediska příliš nemění. [10]

Příklady sítí s učením bez učitele:

- Kohonenova metoda
- Model ART

### 2.3.3.2 Učení s učitelem

Při zadání vstupních parametrů do sítě síť reaguje podle aktuální konfigurace prahových hodnot neuronů s váhových hodnot spojů. V této metodě jsou v době učení porovnávány předem známé požadované výsledky s výstupy sítě a následně je stanovena chyba. Na základě vypočtené chyby se pak snažíme nastavit váhy tak, aby při příštím řešení byla chyba menší. Pro zobecnění řešení je třeba vymežit trénovací množinu vstupních vzorů. Princip učení u živých organismů je podobný, ale učitel nebývá vždy jasně určen – různé okolní vlivy působící jako zpětná vazba. [10] Cílem učení s učitelem tedy je adekvátní změna vah tak, aby poté mohla síť sama nejen přiřadit danému vstupu požadovaný výsledek, ale také aby do té doby neznámému vstupu byla schopna přiřadit přijatelný výsledek, nebo-li aby uměla *generalizovat*. [17]

Příklady sítí s učením s učitelem:

- Backpropagation
- Perceptronová síť
- Hopfieldův model

### 3 Aplikace umělých neuronových sítí

Možnosti praktického využití umělých neuronových sítí se s rychle rostoucím vývojem neustále rostou. Klasické algoritmy dřív skoro nebyly schopny řešit složitější problémy, které bylo velmi obtížně matematicky popsat. Díky možnosti učení se mohou umělé neuronové sítě lépe přizpůsobit danému problému a efektivněji jej řešit. [10] I přes to, že samotná technologie umělých neuronových sítí nabízí velmi perspektivní a četné aplikační možnosti a dokážou nahradit dosavadní konvenčnější informační technologie tam, kde buď selhávaly nebo narážely na potíže, je v mnoha případech výhodnější použití různých hybridních systému právě neuronových sítí a jiných konvenčních systémů. Není tedy příliš reálné, že by technologie založené na neuronových sítích zcela vytlačily všechny ostatní. Nicméně jsou bezpochyby oblasti, kde tato technologie přináší velké a zásadní výhody. [1]

Do těchto úloh se mohou řadit v podstatě všechny, které se týkají zpracování neúplných, nepřesných, rozporných a neurčitých informací, rozpoznávání složitých signálů a obrazů a také problémy ohledně optimalizačního charakteru za obtížných a často časově velmi nestálých podmínek. [1]

Teprve v roce 1984 byly poprvé aplikovány umělé neuronové sítě v praxi. Jednalo se o kanálový vyrovnávač používaný v telefonních systémech na dlouhé vzdálenosti. V dnešní době se neuronové sítě používají v širokém spektru oborů. Jedná se např. o robotiku, sensorové systémy, lékařské aplikace, komunikace, ekonomika, finance, energetika, výrobní pochody, zpracování signálů, aplikace v oblasti řeči a poslechu, strojové vidění, detekce a analýza pohybu, identifikace systémů aj. Své uplatnění najdou i v oblasti předpovědi počasí, analýze časových dat a jejich predikci. V letecké dopravě se používají k lepší práci autopilotů, k simulaci letecké dráhy, v kontrolních systémech, pro detekci poruch materiálu, pro analýzu funkcí jednotlivých částí letadla a určování optimální doby pro generální opravu motorů. Jsou prováděny výzkumy na využití technologie neuronových sítí pro detekci mikrospánku u řidičů vozidel. Také samozřejmě najdeme aplikace v elektrotechnice, např. predikce kódovaných řad, návrhy čipů integrovaných obvodů, nelineární modelování, v kontrolních systémech a opět také analýza vad v materiálech. Nicméně neuronové sítě se používají i v méně tradičních odvětvích, jako je např. zábavní průmysl (animace, speciální efekty), bankovníctví (ověřování dokumentů, předpovědi kurzů měn), armáda (určování cílů, řízení střel, rozlišování objektů, různé druhy sensorů, rozpoznávání osob, komprese dat) aj. Aplikace se dají v podstatě rozdělit do dvou velkých skupin – klasifikace (kam můžeme řadit

i diagnostiku) a predikce. [3] [10]

### 3.1 Umělé neuronové sítě v technické diagnostice

V technické diagnostice se nachází široké spektrum používaných metod a nástrojů podle uplatnění v jednotlivých aplikacích. Oblast umělé inteligence je velice rychle se rozvíjející odvětví také proto, že můžeme prostřednictvím jednotlivých metod velice efektivně zjišťovat určitý stav systému, jeho parametry a hodnoty, analyzovat poruchy a jejich příčiny, ale také předvídat budoucí vývoj daného systému a využít tyto znalosti pro další zpracování. [15]

Mezi používané nástroje v technické diagnostice patří například umělé neuronové sítě, fuzzy systémy, expertní systémy nebo tzv. hybridní fuzzy – neuronové sítě. Pro různé aplikace může být vhodnější jiná metoda nebo jejich kombinace. [10]

#### 3.1.1 Aktuální diagnostika

V oblasti aktuální diagnostiky je pozornost soustředěna na **modelování a identifikaci**. V procesu modelování dochází k tvorbě modelů, při kterém dochází v použití matematicko-fyzikálních experimentů a analýz. Dalo by se říci, že modelování může být jeden ze způsobů zobrazení vnějšího světa, při kterém dochází ke zkoumání v něm existujících pravidel a zákonitostí. Pojem simulace představuje modelování dynamických systémů s přímým nebo nepřímým zpětným způsobem. [15]

Identifikací rozumíme ztotožnění modelu s jeho reálnou předlohou. Identifikace a modelování se navzájem prolínají, tyto procesy by se však neměly zaměňovat. Cílem modelování a identifikace je vytvoření takového modelu, aby jeho chování bylo co nejvíce podobné jeho reálnému zkoumanému systému. Model je tedy systém, fyzický nebo abstraktní, který se přiřazuje v průběhu experimentálního informačního procesu (modelování) k danému zkoumanému systému podle určitých kritérií. [18] [20]

#### Obecný přehled metod modelování

Metody modelování se dají obecně rozdělit do dvou hlavních tříd, a to modelování:

- **fyzikální**
- **abstraktní**

Tyto dvě základní třídy se pak dále dělí na podtřídy podle způsobu vytváření modelu, způsobu popisu modelu atd. [18]

V následujících odstavcích stručně popiši tyto tři druhy modelování:

- *výpočtové*
- *matematické*
- *nekonvenční*

### **Výpočtové modelování**

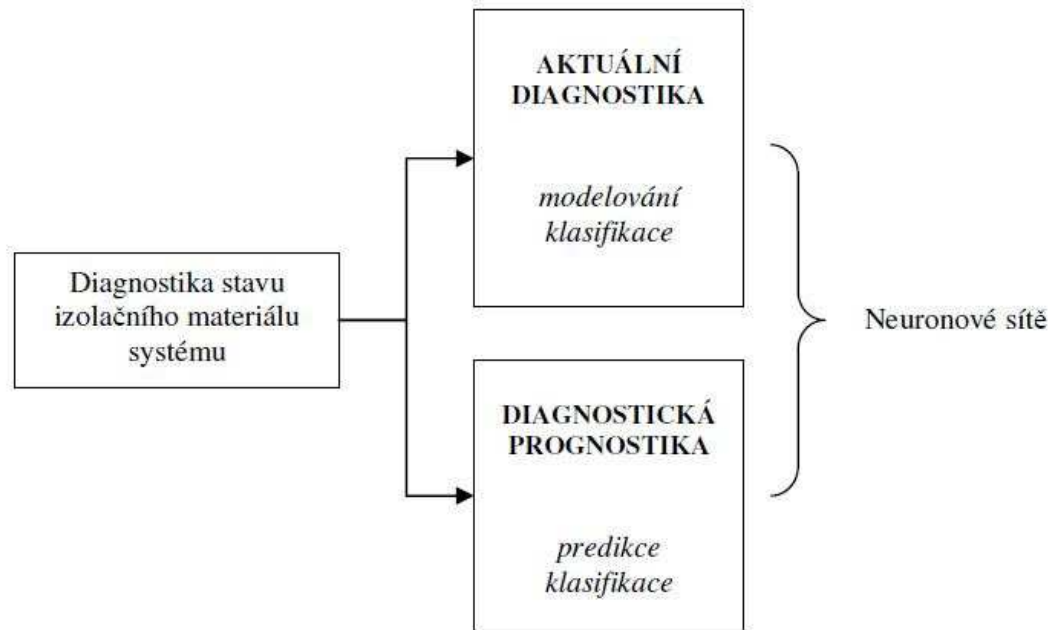
V tomto druhu modelování se uplatňuje zpracování číselných veličin výpočtem. Též se tomuto druhu říká modelování **teoretické**, protože je založeno na využívání určité teorie, vhodné pro řešení určitého problému. Modelovým objektem je zde tedy množina teorií, jež se nabízejí při řešení dané úlohy. Z této množiny je poté vybrána právě ta teorie, která nejlépe vystihuje systém veličin reálného objektu. Tato teorie je pak považována za systém modelového objektu. [15][18]

### **Matematické modelování**

Matematické modelování je velmi významnou podmnožinou již zmiňovaného modelování výpočtového. Také matematický model je chápán jako submodel výpočtového modelu. Existence matematického modelu je nutnou avšak nedostačující podmínkou pro výpočtové modelování. Výpočtové modelování vyžaduje kromě matematického modelu také správnou teorii a existenci vstupních údajů. [18]

### **Nekonvenční modelování**

V tomto modelování není modelovaný reálný systém popsán exaktními a úplnými informacemi v číselné podobě. Jedná se tedy o modelování nenumerické. Tento druh modelování je právě díky neúplnosti informací o daném systému velmi vhodný pro moderní umělé inteligence, např. fuzzy logice, kognitivní vědě a právě neuronovým sítím. Toto modelování dále rozdělujeme na kvalitativní, což je čistě nenumerické, a na semikvalitativní, které se nachází mezi konvenčním a kvalitativním (numerickým a nenumerickým). [20]



Obr. 3.1 Aplikace umělých neuronových sítí v diagnostice stavu izolačního materiálu [15]

### 3.1.2 Modelování umělými neuronovými sítěmi

Modelování patří mezi základní aplikační využití umělých neuronových sítí, kde funkce takové neuronové sítě je chápána jako transformace  $T$  vstupního signálu  $\bar{X}$  na výstupní signál  $\bar{Y}$ , tedy: [18]

$$\bar{Y} = T(\bar{X}) \quad (3.1)$$

Během vývoje vědních disciplín, zabývajících se neuronovými sítěmi, byly vysloveny a dokázány následující teoremy týkající se aproximačních možností transformace  $T$ .

#### Kolmogorův teorém (1957)

Každá spojitá funkce  $f(x_1, x_2, \dots, x_n)$  reálných proměnných definovaná v prostoru  $R^n$  pro  $n \geq 2$ , přičemž jednotlivé proměnné jsou v intervalech  $\langle 0, 1 \rangle$ , může být vyjádřena jako:

$$f(x) = \sum_{j=1}^{2n+1} \chi_j \left( \sum_{i=1}^n \psi_{ij}(x_i) \right), \quad (3.2)$$

kde  $\chi_j$  a  $\psi_{ij}$  jsou spojitě funkce jedné proměnné a  $\psi_{ij}$  je monotónní funkcí nezávislou na funkci  $f$ . [8] [15]

Kolmogorův teorém dále rozšířil Sprecher.

### Sprecherův teorém (1965)

Pro každé celé číslo  $n \geq 2$  existuje reálná, monotónně vzrůstající funkce  $\psi(x)$  v intervalu  $\langle 0, 1 \rangle$ , závislé na  $n$  a mající následující vlastnosti:

*Pro každé zvolené číslo  $\delta > 0$  existuje racionální číslo  $\varepsilon$ ,  $0 < \varepsilon < \delta$  takové, že každá reálná spojitá funkce  $n$  proměnných  $f(x)$  definovaná v  $I^n$  může být vyjádřena jako:*

$$f(x) = \sum_{j=1}^{2n+1} \chi_j \left( \sum_{i=1}^n \lambda_i \psi(x_i + \varepsilon(j-1)) + j - 1 \right), \quad (3.3)$$

Kde  $\chi$  je reálná spojitá funkce a  $\lambda$  je konstanta nezávislá na  $f(x)$ . [15]

V osmdesátých letech dvacátého století byly tyto teorémy aplikovány na problematiku neuronových sítí Hecht – Nielsenem.

### Hecht – Nielsenův teorém

Nechť je dána libovolná spojitá funkce  $f: I^n \rightarrow R^m$ , kde  $I$  je uzavřený jednotkový interval  $\langle 0, 1 \rangle$ . Funkci  $f$  je možno reprezentovat jako transformační funkci vícevrstvé neuronové sítě s dopředným šířením signálů, která má  $n$  výkonných prvků ve vstupní vrstvě,  $2n + 1$  výkonných prvků ve skryté vrstvě a  $m$  výkonných prvků ve výstupní vrstvě. Výkonné prvky ve vstupní vrstvě předávají pouze signály do výkonných prvků skryté vrstvy. Přenosové funkce výkonných prvků skryté vrstvy jsou: [18]

$$z_j = \left( \sum_{i=1}^n \lambda^i \psi(x_j + \varepsilon_j) + j \right), \quad (3.4)$$

kde reálné konstanty  $\lambda_i$  a spojitě, monotónně rostoucí funkce  $\psi$  jsou nezávislé na  $f$  (ačkoliv závisí na  $n$ ) a kde konstanty  $\varepsilon$  splňují podmínku Sprecherova teorému. Přenosové funkce výkonných prvků výstupní vrstvy jsou:

$$y_k = \sum_{j=1}^{2n+1} g_k z_j, \quad (3.5)$$

kde  $g_k$  jsou reálné a spojitě funkce, závislé na  $f$  a  $\varepsilon$ . [15]

Hornik, Stinchcombe a White potom v roce 1989 na základě Hecht – Nielsenova teorému dokázali, že vícevrstvá neuronová síť s výkonnými prvky, které mají libovolné

hladké přenosové funkce, může svou transformační funkcí aproximovat libovolnou danou funkci s libovolnou přesností. Hladkou funkcí zde rozumíme neklesající funkci  $f(x)$ , pro kterou platí:  $0 \leq f(x) \leq 1$  pro všechna  $x$ ,  $f(x) \rightarrow 0$  pro  $x \rightarrow -\infty$  a pro  $f(x) \rightarrow 1$  pro  $x \rightarrow \infty$ . [18] [20]

### 3.1.3 Aktuální klasifikace neuronovými sítěmi

Proces, při kterém se rozhoduje o tom, do které třídy zařadit předmět popsáný vstupním vektorem, se nazývá **klasifikace**. Vstupní prostor je tedy rozkládán na jednotlivé třídy, každá představující určitou kategorii. **Klasifikátorem** pak rozumíme příslušný algoritmus, který klasifikaci provádí. Klasifikátor definuje rozhodovací pravidlo, tedy zobrazuje množinu vektorů příznaků na množinu indikátorů tříd. Vektor příznaků je pak vektor z obrazců odvozených numerických charakteristik, na základě kterých lze tyto obrazce navzájem odlišit. Klasifikátor lze nastavit tak, že analyzujeme problém a definujeme rozhodovací pravidla ještě před klasifikací, nebo sestavíme rozhodovací pravidla s použitím objektů, jejichž správná klasifikace je předem známá – nastavování klasifikátoru učením pomocí trénovací množiny. Množina vektorů příznaků se známou klasifikací je pak danou trénovací množinou. [18]

Pro správnou funkčnost klasifikátoru je potřeba ho správně naučit řešit daný problém. K tomu se využívají dva základní přístupy. O tomto jsem se již zmiňoval v kapitole 2.3.3, nicméně ve zkratce:

- Učení s učitelem

Klasifikátor si zapamatuje předložené objekty se známou klasifikací a podle toho pak zařazuje neznámé objekty do daných tříd. Tento proces je celkem časově náročný a hrozí riziko, že učitel přiřadí objekt do špatné třídy (chyba v trénovacích datech)

- Učení bez učitele

V této metodě je třeba, aby klasifikátor nejdříve odhalil v parametrickém prostoru třídy objektů. Toto je provedeno např. pomocí vyhledávání shluků v parametrickém prostoru, čímž se zabývá např. hierarchické shlukování, shluková analýza, apod.

Obvykle se u neuronových sítí určené ke klasifikaci tříd používá k učení metoda první. Topologie je pak dána samotným klasifikačním problémem. Počet výkonných prvků ve výstupní vrstvě odpovídá počtu tříd klasifikace. Pokud příslušný vzor patří do té či oné třídy, pak je toto při učení sítě na výstupech označováno například hodnotami 0 a 1. Síť je možno

celkem dobře naučit, pokud máme k dispozici dostatečné množství tréninkových předloh – např. několikanásobek počtu klasifikačních tříd. Přivedeme-li potom na již naučenou neuronovou síť vzor s neznámou klasifikací, na výstupech výkonných prvků výstupní vrstvy se objeví signály, které charakterizují pravděpodobné přiřazení neznámého vzoru do určité klasifikační třídy. Spolehlivost této klasifikace je celkem vysoká, pokud má síť dobrou generalizační schopnost. Pokud se jedná právě o **aktuální klasifikaci**, pak mluvíme o klasifikaci do aktuálních tříd v aktuálním čase  $t$  na základě aktuálních vstupních vzorů (získané např. v aktuálním čase  $t$ ). V diagnostice tedy touto klasifikací na základě naměřených dat klasifikujeme aktuální stav diagnostikovaného objektu. Topologie neuronových sítí **RBF** a **LVQ** tyto druhy velmi vhodnými pro řešení klasifikačních úloh. [18]

### 3.1.4 Predikce neuronovými sítěmi

Predikce, nebo-li předpovídání je určování skutečností o budoucím stavu, většinou na základě předchozích nebo aktuálních informací. V technice se často popisují předpovídané parametry rovnicemi, čímž se omezuje předpověď pouze na výpočet (řešení) daných rovnic. V praxi se ovšem setkáváme se situacemi, jejichž popis rovnicemi by byl příliš složitý nebo dokonce nemožný. Řešení by pak v těchto případech bylo extrémně časově náročné, dokonce by mohlo dojít dříve k predikovanému jevu, než by byl určen výpočtem. Také se dá použít aproximování dat regresí závislosti predikovaného jevu na okolnostech, kterou pak extrapolujeme do budoucnosti, ale i toto může být časově náročné. [20]

Výhoda použití neuronových sítí je v jejich automatickém naučení závislosti pouze z naměřených dat a není potřeba udávat další informace. Trénink sítě spočívá v hledání skrytých závislostí u dat v minulosti a jejich následné využití pro predikci budoucnosti. Jako další výhoda je, že jsou neuronové sítě schopny se učit na příkladech a po naučení můžou odhalit i skryté i silně nelineární závislosti a to i za přítomnosti šumu v trénovací množině. Nevýhodou pak naopak může být skutečnost, že se síť naučí závislosti pouze pro určité období. Odhad chyby predikce je také zpravidla nemožné. Pro tuto aplikaci se používají zejména sítě Backpropagation, RBF a LVQ. [18] [20]

### 3.1.5 Prognostická klasifikace neuronovými sítěmi

Teorie a struktura sítí určených pro prognostickou klasifikaci stavu diagnostikovaného objektu je podobná jako u sítí, které se používají pro aktuální klasifikaci. Nicméně prognostická klasifikace provádí klasifikaci do tříd, které budou platit v budoucím čase  $t + N$ , v závislosti na vstupech získaných např. v čase  $t, t - 1, t - 2, \dots, t - N$ .



Pokud bychom například hovořili o prognostické klasifikaci v diagnostice izolačních materiálů, pak na základě dat, které jsme naměřili v časech  $t, t - 1, t - 2, \dots, t - N$ , proběhne klasifikace stavu daného objektu do určité klasifikační třídy v budoucím čase, tedy  $t + N$ . Daná klasifikační třída pak bude charakterizovat stav nebo degradaci diagnostikovaného objektu v budoucím čase, např. pro čas příštího měření. Pro tuto klasifikaci se také používají kvůli svým vlastnostem zejména sítě typu RBF a LVQ. [18]

## 4 Softwarová prostředí pro práci s neuronovými sítěmi

Popularita metodologie neuronových sítí rychle stoupá v nejrůznějších oblastech od základního výzkumu po vytěžování dat (data mining), v oblastech predikcí v komerční sféře, řízení rizik, marketingu a další.

V této kapitole budou popsány některé softwarové aplikace, které se využívají pro různá praktická využití umělých neuronových sítí.

### 4.1 STATISTICA Automatizované neuronové sítě

Systém STATISTICA Automatizované neuronové sítě je jednou z nejpokročilejších a nejvýkonnějších aplikací technologie neuronových sítí dostupná na současném trhu. Systém nabízí množství jedinečných prostředků a je určen nejen pro specialisty v oboru neuronových sítí (kterým nabízí mimořádný rozsah typů sítí a trénovacích algoritmů), ale i pro nové uživatele této technologie (pro které je k dispozici Automatický vyhledávač sítě, nástroj, který uživatele provede všemi kroky potřebnými pro vytváření neuronových sítí). [21]

#### 4.1.1 Implementace neuronových sítí

Automatický vyhledávač sítě provede uživatele krok po kroku postupem pro vytvoření skupiny rozdílných sítí a výběrem nejvhodnější sítě s nejlepším výkonem (což je úloha, která by jinak vyžadovala zdlouhavý postup metodou "pokusů a omylů" při solidních znalostech základní teorie). Integrovaný pre a post-processing obsahující výběr dat, kódování jmenovitých hodnot, škálování, normalizaci a nahrazování chybějících hodnot s interpretací pro klasifikaci, regresi a problematiku časových řad. *SANS* v sobě integruje vyspělé, vysoce optimalizované trénovací algoritmy včetně metody konjugovaných gradientů a metody Broyden-Fletcher-Goldfarb-Shanno (BFGS). Dále nabízí plnou kontrolu nad všemi aspekty, které ovlivňují chování neuronové sítě, jako je aktivační a chybová funkce nebo komplexnost sítě. Podpora kombinací sítí a síťových architektur prakticky neomezené velikosti organizovaných v sadách neuronových sítí pro vytváření kolekcí. Komplexní grafická

a statistická zpětná vazba poskytující interaktivní průzkumné analýzy. [17] [21]

Plná integrace v rámci systému STATISTICA je samozřejmostí. Všechny výsledky, grafy, reporty atd. mohou být dále upravovány pomocí grafických a analytických nástrojů systému STATISTICA. [21]

#### 4.1.2 Automatické vyhledávání sítě

Automatické vyhledávání sítě zahrnuté v systému STATISTICA Automatizované neuronové sítě je nástroj poskytující výpočet velkého počtu různých architektur neuronových sítí různé komplexnosti a výběr toho nejlepšího souboru specifických architektur pro řešení problému. Významná část času během návrhu neuronové sítě je strávena výběrem vhodných proměnných a následně optimalizováním architektury sítě za pomoci heuristického vyhledávání. Toto vyhledávání zahrnuje typ neuronové sítě, velikost neuronové sítě a její architekturu, aktivační funkce a dokonce i chybové funkce, pokud je to vhodné. [21]

#### 4.1.3 Trénování sítě

STATISTICA Automatizované neuronové sítě podporuje nejlepší známé vyspělé trénovací algoritmy. *SANS* obsahují rychlé trénovací algoritmy druhého řádu: metodu konjugovaného gradientu a BFGS. Je zde i méně paměťově náročná verze BFGS, do které se *SANS* automaticky přepnou, když je velikost paměti na vašem počítači na kritických úrovních. Tyto algoritmy typicky konvergují mnohem rychleji než algoritmy prvního řádu, jako je metoda gradientního spádu. Iterativní trénovací procedura, která je implementovaná v *SANS*, je doplněna automatickým sledováním obou chyb, trénovací a nezávislé testovací chyby. Trénování může být kdykoliv ukončeno ručně uživatelem, nebo může být též blíže specifikována podmínka pro zastavení. Pokud dojde k přeučení, *SANS* si automaticky ponechají kopii nejlepší objevené sítě, která je automaticky získána a použita jako nejlepší řešení. Když je trénování ukončeno, můžete na závěr vyzkoušet výkonnost na trénovacích, testovacích a validačních vzorcích. *SANS* též obsahují řadu trénovacích algoritmů pro shlukovou analýzu, které jsou založeny na Kohonenovo algoritmu pro samoorganizované mapy. [21]

## 4.2 NetVisualiser

Tento program byl vytvořen Petrem Marťanem jako součást jeho diplomové práce na Masarykově Univerzitě v roce 2002. Tento program umožňuje pomocí vizualizačních metod demonstrovat schopnosti některých typů umělých neuronových sítí, jmenovitě to pak jsou:

- Lineární perceptron
- RBF
- Backpropagation
- Kohonenova síť
- Kohonenova mapa

Tyto modely představují základní typy umělých neuronových sítí, a proto byly také autorem programu zvoleny. V samotné diplomové práci Petra Marťana lze nalézt popis implementace neuronových sítí, obecný přehled vybraných typů neuronových sítí aj. Tato diplomová práce [22] je společně s programem NetVisualiser [23] volně dostupný na webových stránkách pana Marťana.

### 4.2.1 O programu

Pomocí programu NetVisualiser je možné vytvořit podle uživatelem zadaných parametrů vytvářet modely vybraných neuronových sítí a následně je učit. U samotného procesu učení je na výběr z několika rychlostí a také různých vizualizačních režimů. Je možné měnit parametry sítě v procesu učení a ovlivňovat tím adaptaci sítě. Grafem chyby učení a statistikou sítě je možné vizualizovat efektivnost učení. Vizualizaci učení neuronové sítě lze využít v režimu klasifikace vzorů pro dvojrozměrná data a v režimu aproximace funkcí pro data jednorozměrná. [17] [22]

Modely neuronových sítí v programu NetVisualiser pracují ve dvou základních režimech, a to: klasifikace vzorů a aproximace funkcí. Samozřejmostí je možnost ukládání natrénované sítě pro pozdější načtení pro potřebu dalšího trénování a nebo demonstraci jejích vlastností. Program umožňuje práci s trénovacími a testovacími daty. Dvojrozměrná data se dají pomocí grafického uživatelského rozhraní vytvářet přímo v programu. Nicméně program umí trénovací data sám generovat. [17] [22]

### 4.3 Jiná softwarová prostředí

Mezi další programy využívající technologií neuronových sítí patří jak komerční tak nekomerční programy. Přehled následujících programů je jen ilustrativní a jistě by bylo možné nalézt i další velmi kvalitní softwarové aplikace. [17]

- Souhrnné označení **NeuralDimension** v sobě zahrnuje programy, které nabízejí řešení prostřednictvím neuronových sítí implementovaných do různých programů, jako je MS Excel, MATLAB, aj.
- Právě matematický software MATLAB je možné rozšířit o možnost tvorby a simulace neuronových sítí pomocí přídatného toolboxu prodávaného pod názvem Neural Network Toolbox<sup>TM</sup>. [24]
- Společnost *SAS* nabízí balík **Enterprise Miner<sup>TM</sup>**, ve kterém je na výběr z několika architektur neuronových sítí sloužící pro data mining. [25]
- Pro operační systém Linux je k dispozici například program Stuttgart Neural Network Simulator - **SNNS**, který byl vyvinut na Stuttgartské Univerzitě. [26]
- Program **Neurex** je výtvozem Ivo Vondráka a jedná se o expertní systém založený na bázi neuronových sítí. [27]
- Existují další programy a softwarové balíky využívající umělé neuronové sítě. Například **Neuronek**, **EasyNN-plus software**, **BrainMaker** aj.

## Závěr

V dnešní době je potřeba řešit velmi složité algoritmy a je zapotřebí používat metody, které dané algoritmy dokážou řešit. I díky umělým neuronovým sítím je možné některé tyto problémy řešit a dosáhnout tak uspokojivých výsledků. V praxi je třeba dbát na to, že každý problém je specifický a vyžaduje nalezení správné sítě.

Tuto bakalářskou práci jsem rozdělil do čtyř kapitol a příslušné dílčí subkapitoly. V první kapitole je popsána historie problematiky nejen umělých neuronových sítí, ale i snah o pochopení lidské mysli jako takové. Druhá kapitola zahrnuje rozdíly mezi neurony – biologickým a umělým. Dále se v ní píše o základních vlastnostech umělé neuronové sítě a také o jednotlivých metodách učení neuronové sítě – metoda s učitelem a bez učitele. Ve třetí kapitole jsem se věnoval praktickému využití umělých neuronových sítí, zejména pak základnímu užití v technické diagnostice, kde jsou neuronové sítě hojně využívány. V technické diagnostice se neuronové sítě využívají hlavně v aktuální a prognostické klasifikaci, pro modelování neuronovými sítěmi a v prognostické diagnostice, kde se na základě známých dat predikuje stav budoucí. V poslední kapitole jsem se zmínil o některých softwarových aplikacích, které se dají v problematice umělých neuronových sítí využít.

Umělé neuronové sítě si už v elektrotechnice vybudovaly své postavení a mají určitě budoucnost. Oblast využití těchto systému se stále rozrůstá.

## Použitá literatura

- [1] M. Novák a kol. *Umělé neuronové sítě teorie a aplikace*. Praha: C.H.BECK, 1998.
- [2] V. Mařík, O. Štěpánková, J. Lažanský a kol., *Umělá inteligence 1,1*. vyd. Praha: AV ČR, 1993.
- [3] J. Tučková, *Vybrané aplikace umělých neuronových sítí při zpracování signálů*, 1. vyd. Praha: ČVUT, 2009
- [4] W. Grey Walter, *Cybernetic Animals* [online]. Cit. 11.4.2012, Dostupný z: <http://cyberneticzoo.com/wp-content/uploads/Minsky-Papert-71-cSolomon-x640.jpg>
- [5] Z. Ludvíková, *Vývoj mozku dítěte a jeho správná stimulace* [online]. Cit. 12.4.2012 Dostupný z: [http://casopis.mensa.cz/veda/vyvoj\\_mozku\\_dit236te\\_a\\_jeho\\_spravna\\_stimulace.html](http://casopis.mensa.cz/veda/vyvoj_mozku_dit236te_a_jeho_spravna_stimulace.html)
- [6] J. Koutník, *Neuronové sítě a neuropočítače* [online]. Cit. 15.4.2012, Dostupný z: <http://neuron.felk.cvut.cz/courseware/data/chapter/36nan007/2.gif>
- [7] L. Horký, K. Břinda, *Neuronové sítě* [online]. Fakulta jaderná a fyzikálně inženýrská, Praha, Cit. 17.4.2012 Dostupný z: <http://fyzsem.fjfi.cvut.cz/2008-2009/Leto09/proc/neurony.pdf>
- [8] J. Šíma, R. Neruda: *Teoretické otázky neuronových sítí* [online]. Cit. 24.4.2012, Dostupný z: <http://www2.cs.cas.cz/~sima/kniha.pdf>
- [9] Ömer Cengiz, *Neural Network* [online], Cit. 3.5.2012 Dostupný z: [http://www.byclb.com/TR/Tutorials/neural\\_networks/ch7\\_1.htm](http://www.byclb.com/TR/Tutorials/neural_networks/ch7_1.htm)
- [10] M. Prušák, *Neuronové sítě v elektrotechnice*, Plzeň 2009
- [11] J. Fand, *Neuronové sítě ve společenských vědách*, 2000
- [12] *Topologie umělých neuronových sítí*, Cit. 6.5.2012 Dostupné z: [http://sofe2.pepiino.cz/wiki/doku.php?id=topologie\\_umelych\\_neuronovych\\_siti](http://sofe2.pepiino.cz/wiki/doku.php?id=topologie_umelych_neuronovych_siti)
- [13] M. Fajfr, *Použití umělých neuronových sítí pro rozpoznávání mluvené řeči*, 2010
- [14] ArtInt, 2010, Cit. 6.5.2012 Dostupné z: <http://www.artint.wz.cz/?page=neuronovasi>
- [15] T. Malý, *Metody umělé inteligence*, Plzeň 2008
- [16] M. Novák, *Neuronové sítě a neuropočítače*, 1992
- [17] R. Biskup, *Možnosti neuronových sítí*, Praha 2009
- [18] M. Hammer, *Metody umělé inteligence v diagnostice elektrických strojů*, Praha 2009
- [19] M. Kreidl, R. Šmíd, *Technická diagnostika*, Praha 2006
- [20] M. Hammer, P. Kratochvíl: *Aplikace umělé inteligence v diagnostice izolačních*

*materiálů*. Plzeň, 2006

- [21] StatSoft, *STATISTICA Automatizované neuronové sítě* [online], cit. 28.5.2012  
Dostupný z: <http://www.statsoft.cz/produkty/4-neuronove-site/20-statistica-automatizovane-neuronove-site-cz/detail/>
- [22] P. Maršan, *Vizualizace vybraných metod strojového učení* [online], cit. 1.6.2012,  
Dostupný z: <http://neuralnets.czweb.org/dpPetrMartan2002.pdf>
- [23] P. Maršan, *NetVisualiser* [online], cit. 1.6.2012, Dostupný z:  
<http://neuralnets.czweb.org/NetVisualiser.zip>
- [24] MathWorks, *MATLAB Neural Network Toolbox<sup>TM</sup>* [online], cit. 1.6.2012,  
Dostupný z: <http://www.mathworks.com/products/neural-network/>
- [25] SAS, *Enterprise Miner<sup>TM</sup>* [online], cit. 1.6.2012, Dostupný z:  
<http://www.sas.com/technologies/analytics/datamining/miner/neuralnet/index.html>
- [26] The SNNS Team, *Stuttgart Neural Network Simulator* [online], cit. 1.6.2012,  
Dostupný z: <http://www.ra.cs.uni-tuebingen.de/SNNS/>
- [27] I. Vondrák, *Neurex – Expertní systém na bázi neuronových sítí*, Ostrava 1993