

Bankovní institut vysoká škola Praha
Katedra informačních technologií a elektronického obchodování

Základní principy umělé inteligence
Diplomová práce

Autor: **Bc. Jiří Pazika**
Informační technologie a management

Vedoucí práce: **Ing. Vladimír Beneš Petrovický**

Praha

Duben 2009

Prohlášení:

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a s použitím uvedené literatury, materiálů a zdrojů.

V Praze dne 14. dubna 2009

Bc. Jiří Pazika

Poděkování:

Chtěl bych na tomto místě poděkovat svému vedoucímu mé diplomové práce panu Ing. Vladimíru Benešovi Petrovickému za poskytnuté konzultace nad obsahovou i stylistickou stránkou práce a za jeho věcné a praktické připomínky ke správnému dokončení celého obsahu této práce. Dále pak bych chtěl poděkovat všem mým spolupracovníkům v mém zaměstnání za poskytnutí odborné literatury a specializovaných časopisů umožňujících celkové zpracování všech poznatků uvedených v této diplomové práci.

V Praze dne 14. dubna 2009

Bc. Jiří Pazika

Anotace práce:

Tato diplomová práce se zabývá moderním vědním oborem nazvaným umělá inteligence a popisuje její základní principy. Hned na začátku nám v první části umělou inteligenci představí v několika tezích a definicích, které nás pak přenesou do kapitoly popisující historické základy této vědní disciplíny až po současnost. Poté se v další části této práce pojednává o rozdělení umělé inteligence do jednotlivých kategorií. V kapitole popisující neuronové sítě jsou představeny základní pojmy používané v této oblasti, vývoj neuronových sítí, struktura a funkčnost, analytické schopnosti i jejich možnosti praktického využití. V závěru se tato práce zabývá aplikací umělé inteligence v některých oborech současnosti.

Description of the work:

This thesis deals with the modern scientific field called artificial intelligence and describes its basic principles. In the first part of the thesis is the artificial intelligence described in several theses and definitions, which will lead us to the chapter describing the historical foundations of this discipline to the present. Then in further part of this thesis it deals with the dividing of artificial intelligence into individual categories. Within the chapter describing the neural networks are presented the basic concepts used in this area, the development of neural networks, structure and functionality, analytical skills and their ability to practice. In conclusion, this work deals with the applications of artificial intelligence in some areas of the present time.

Obsah:

| | |
|---|-----------|
| ÚVOD | 6 |
| 1 TEZE O UMĚLÉ INTELIGENCI..... | 8 |
| 1.1 Některé definice umělé inteligence..... | 9 |
| 1.1.1 Definice umělé inteligence a zákony robotiky..... | 9 |
| 1.1.2 Další definice umělé inteligence..... | 11 |
| 1.2 Co umí umělá Inteligence | 13 |
| 1.3 Umělá inteligence jako vědní disciplína | 14 |
| 1.4 Dva pohledy na umělou inteligenci | 14 |
| 1.5 Umělá inteligence - zatím vzdálený sen | 14 |
| 1.6 Lidský mozek má výkon 38 petaflops a paměť 3 581 TB | 15 |
| 2 VÝVOJ A SOUČASNÝ STAV UMĚLÉ INTELIGENCE | 17 |
| 2.1 Minulost umělé inteligence | 17 |
| 2.2 Současnost umělé inteligence..... | 18 |
| 3 KATEGORIZACE UMĚLÉ INTELIGENCE | 20 |
| 3.1 Umělá inteligence není jen pouhý slovní výraz..... | 20 |
| 3.1.1 Expertní systémy | 20 |
| 3.1.2 Genetické algoritmy | 21 |
| 3.1.3 Neuronové sítě..... | 21 |
| 3.2 Jaká je praxe v českých poměrech..... | 22 |
| 4 NEURONOVÉ SÍTĚ | 23 |
| 4.1 Specifika neuronových sítí..... | 23 |
| 4.2 Vývoj neuronových sítí | 24 |
| 4.3 Základní pojmy | 25 |
| 4.4 Neuronové sítě - učení..... | 30 |
| 4.4.1 Jak neuronová síť funguje | 30 |
| 4.4.2 Neuronové sítě a regresní modely | 32 |
| 4.4.3 Způsob učení (trénování)..... | 34 |
| 4.4.4 Topologie neuronových sítí | 38 |
| 4.4.5 Standardizace dat | 41 |
| 4.5 Další typy neuronových sítí | 43 |
| 4.5.1 Vícevrstvá síť perceptronů a metoda backpropagation..... | 43 |
| 4.5.2 Význam neuronových sítí s aktivační funkcí sigmoida | 43 |
| 4.5.3 Asociativní síť | 44 |
| 4.5.4 Hopfieldova síť..... | 44 |
| 4.5.5 Samoorganizace..... | 45 |
| 4.6 Oblasti využití neuronových sítí..... | 45 |
| 4.6.1 Neuronové sítě a co s nimi..... | 46 |
| 4.6.2 Simulátory neuronových sítí..... | 51 |
| 4.7 Návrhy možného využití neuronové sítě | 54 |
| 4.7.1 Ekonomické informační systémy. | 54 |
| 4.7.2 Vyhodnocení finanční situace podniku..... | 56 |
| 5 APLIKACE UMĚLÉ INTELIGENCE | 57 |
| 5.1 Příklady reálných aplikací | 57 |
| 5.2 Aplikace genetických algoritmů..... | 58 |
| 5.3 Řešení omezujících podmínek..... | 59 |
| 5.3.1 Problém obchodního cestujícího..... | 59 |
| 5.4 Člověk versus kyborg..... | 61 |
| 5.5 Umělá inteligence a viry..... | 62 |
| ZÁVĚR | 68 |
| SEZNAM POUŽITÉ LITERATURY A ZDROJŮ | 70 |
| SEZNAM OBRÁZKŮ | 72 |

Úvod

Umělá inteligence. Toto slovní spojení, které ještě donedávna patřilo převážně na stránky vědecko-fantastické literatury, se stalo součástí našeho každodenního života. Současnost umělé inteligence je ve znamení mnoha směrů výzkumu a aplikací, kde převážnou většinu z nich už dávno široká veřejnost nechápe jako jevy mimořádné a zvláštní.

Jako jedna z hlavních aplikačních oblastí se rozvíjí okruh znalostních a expertních systémů. Jsou to programy, které v sobě obsahují expertizu úvah lidských specialistů a jsou schopné pomáhat řešit problémy v určitém oboru lidem, kteří jsou v řešení problémů málo zkušení, anebo naprosto nezkušení. Stále více se využívají expertní systémy v nových oblastech. I v těch, kde by ještě donedávna jejich aplikace byla nemyslitelná či nepředstavitelná. Přitom ale mnohdy není úplně viditelné, že uživatel má něco společného s nějakým expertním systémem, neboť tyto systémy jsou často součástí většího programového celku nebo i celého zařízení. Například expertní systémy, tvořící součást navigačních a řídicích systémů letadel, kosmických lodí, anebo i vyšších tříd automobilů. Ve vojenství pak kromě letadel nalézají expertní systémy velké využití v různých naváděcích systémech některých typů zbraní.

Můžeme tedy říci, že všude tam, kde je k řešení problémů zapotřebí znalostí odborníků, tedy lidí, kteří jsou v dané oblasti hluboce vzdělaní a zkušení, je možnost vytvořit a prakticky využít expertní systém. Expertní systémy nám umožňují nacházet použitelná řešení i v těch případech, kdy konvenční algoritmičká řešení, selhávají. Expert je schopen použítelné řešení nalézt, aniž by musel k němu přijít pomocí nějakého přímého výpočtu či algoritmu. A expertní systémy v mnohém napodobují činnost těchto expertů.

V dnešní době se častěji místo pojmu expertní systém používá pojem znalostní systém. Tím se zdůrazňuje úloha využití expertních znalostí jako základu pro fungování těchto systémů. Jde o vyústění moderních trendů managementu, kde došlo k většímu uvědomění si podstatné úlohy znalostí v rozvoji konkurenceschopnosti organizací. Tím tak docházíme i k formulaci teze, že současná lidská společnost je ve svém rozvoji na cestě přes společnost informační ke společnosti znalostní, ve které jsou naprosto zásadním zdrojem dalšího rozvoje a pokroku znalosti.

Předcházející trend uvědomění si mohutné síly a rozhodující úlohy znalostí pro další rozvoj organizací i společnosti vedl k mocnému rozvoji oblasti zvané management znalostí. Ten lze definovat jako systematický proces vyhledávání nebo výběru organizace,

koncentrace a prezentace znalostí způsobem, který pomáhá v organizacích zvyšovat jejich úroveň. Management znalostí pomáhá pracovníkům v organizacích docílit hlubšího vhledu a porozumění problémům, které řeší a postupům, které používají a to zejména na základě využití vlastních zkušeností. Dotýká se tedy lidí a těch procesů, v rámci kterých lidé sdílejí informace, budují na jejich základě znalosti a přispívají k budování a rozvoji společné sdílené firemní znalosti neboli korporativní paměti.

A právě zde můžeme dále navázat na využití umělé inteligence - expertní systémy, nebo jejich součástí zvané báze znalostí. Ty tvoří velice vhodnou technologickou základnu pro budování a udržování sdílené firemní znalosti. Řada komerčně dostupných programových řešení pro zavádění managementu znalostí do organizací právě tyto výsledky výzkumu umělé inteligence využívá.

Další oblasti výzkumu umělé inteligence, kromě teoretických oblastí, se orientují na ulehčení řešení běžných životních situací. Jako je výzkum a aplikace systémů umělé percepce (vjem vidění, slyšení a hmatové systémy), které skýtají novou perspektivu smyslově postiženým lidem. Ale i výzkum decentralizované inteligence, která by mohla, zejména ve spojení s mobilními telekomunikačními technologiemi představovat úplně novou kvalitativní úroveň života.

V jiném směru lze možné vyústění výzkumu umělé inteligence vidět ve snahách o vytvoření inteligentních strojů-robotů, nebo alespoň ve snahách o doplnění chybějících smyslů či částí těla zdravotně postiženým lidem dokonalou umělou smyslovou náhradou. Zde se postupně můžeme dopracovat k úvahám o inteligentních robotech, kteří mohou třeba někdy budoucnu i nahradit člověka.

Cílem této diplomové práce je objasnit vývoj a možnosti umělé inteligence včetně praktického využití v oblasti výpočetní techniky.

1 Teze o umělé inteligenci

Co si lze myslet pod umělou inteligencí? Je něco takového vůbec možné? Převezme umělá inteligence někdy roli člověka? Je možné věřit tomu, že s rozvojem robotiky a umělé inteligence budou vznikat chytré automaty, které nám tato očekávání uskuteční bez naší práce a účasti na výrobním procesu? Anebo každý automat či robot zůstane vždy pouze důmyslným a drahým mechanismem, který dělá přesně to, pro co je určen a na co je člověkem naprogramován?

Pod pojmem umělá inteligence, se chápe inteligentní stroj, tedy věc neživá. Každá inteligence nějak souvisí s vědomím. Nelze si představit jedno bez druhého. Uchopit inteligentně nějakou věc znamená uvědomit si její význam v kontextu reálného světa. Pro toto uvědomění však nestačí popsat ji v jednotlivostech či vyjmenovat jisté relace. Existence popisu zkoumaného objektu pak ještě není vědomím o něm, jako o identické věci. Inteligence musí danou věc vnímat jako součást celku a o tom celku musí mít nějaký pojem, přitom onen celek se nedá vyjádřit konečným popisem jeho jednotlivostí. Vědomí není popis světa rozložený do prvků a vztahů mezi nimi, jako se modeluje reálný svět objektů v počítačových databázích. Na druhé straně každá inteligence musí být vztažena k nějakému subjektu jako k jejímu nositeli, neexistuje sama o sobě, ale jako vlastnost nebo lépe řečeno schopnost určitého subjektu. Bez subjektu nelze žádnou inteligenci vůbec myslet. Jestliže tedy inteligence má vědomí o věcech, nutně musí mít také vědomí o sobě, o svém vlastním já. Musí si uvědomit sebe jako věc, která je inteligencí obdařena.

Je-li tedy inteligence odkázána na svůj vlastní subjekt, musí nutně chápat svoji podmíněnost existencí sama sebe jako věci o sobě a následně ji začít vnímat jako hodnotu, kterou je nutné zachovat. Inteligentní subjekt má proto starost o vlastní zachování. A to je podstata živého tvora. Musí být proto živým subjektem. Inteligentní subjekt proto nutně objevuje překážky vlastního bytí. Začíná hledat a nacházet své nepřátele a proti nim se aktivizuje. Pokud tedy člověk vytvoří inteligenci, vytvoří inteligentní živou bytost. A pokud tuto bytost bude chtít mít pod kontrolou či užívat ji ke své potřebě, zákonitě se vůči ní profiluje jako nepřítel. Inteligentní bytost musí pochopit takové ohrožení.

1.1 Některé definice umělé inteligence

Strojově orientovaný náhled:

- Umělá inteligence je zkoumání principů umožňujících počítačům být inteligentními.

Náhled orientovaný na lidské myšlení:

- Umělá inteligence je zkoumání mentálních schopností prostřednictvím výpočetních modelů.

Obecný a vyčerpávající pohled:

- Umělá inteligence je schopnost člověkem vytvořených strojů emulovat a simulovat lidské metody pro deduktivní a induktivní akvizici a aplikaci znalostí a odvozování.

Definice profesora Marvina Minského¹:

- Umělá inteligence je věda o vytváření strojů využívajících postupy a činnosti prováděné člověkem, které by vyžadovaly jeho inteligenci

1.1.1 Definice umělé inteligence a zákony robotiky

S umělou inteligencí se začínají spojovat i první stroje-roboti, které již vykazují jednoduchou inteligenci. K tomu, aby mohlo něco takového spolehlivě fungovat je nutné vědět, co to je a jak to funguje. Jinými slovy je nutné hlavně vědět, co to je inteligence jako taková, co je to za proces a co lze od něho očekávat. Do dnešního dne bylo publikováno mnoho definic umělé inteligence, které by ji měli ozřejmit. Jako například:

- Umělá inteligence je označení uměle vytvořeného jevu, který dostatečně přesvědčivě připomíná přirozený fenomén lidské inteligence.
- Umělá inteligence označuje tu oblast poznávání skutečnosti, která se zaobírá hledáním hranic a možnosti symbolické, znakové reprezentace poznatku a procesu jejich nabývání, udržování a využívání.

¹ Marvin Lee Minsky (* 9. srpna 1927) je americký vědec zabývající se umělou inteligencí. Je spoluzakladatelem laboratoře umělé inteligence a autor několika filosofických textů. (Zdroj: http://cs.wikipedia.org/wiki/Marvin_Minsky).

- Umělá inteligence se zabývá problematikou postupu zpracování poznatku - osvojováním a způsobem použití poznatku při řešení problému.

Další definice inteligence je mnohdy subjektivní záležitostí, což je charakteristické zejména pro začátky tohoto oboru. Například britský matematik A. Turing² definoval inteligenci operačně. To znamená pomocí experimentu, v němž se lidský operátor snažil určit na základě komunikace člověk/stroj identitu druhé strany. Jestliže nebylo možno vydat rozhodnutí o identitě druhé strany, pak stroj komunikující s člověkem byl označen za inteligentní.

Pohled na definici inteligence může různě vyjádřit člověk jenž má nižší vzdělání a jiný člověk například s vysokoškolským vzděláním.

Vlastní výraz umělá inteligence byl poprvé použit v roce 1956 v USA. Autorem tohoto výrazu byl jistý John McCarthy³. Podle jeho definice umělá inteligence zahrnuje:

- Hraní her - stroje by měli být schopny hrát i takové složité hry jako jsou například šachy.
- Expertní systémy - stroje by měly být schopny konat správná rozhodnutí v reálných situacích. Jako jsou lékařské diagnózy, strategické rozhodování na bojišti, na finanční burze.
- Zpracování hlasu: stroje by měly být schopny nejen zpracovat hlas, což dnes už není nic nevdědního, ale měly by také být schopny rozumět smyslu zprávy, jenž byla vyslovena a umět na ni správně zareagovat.
- Neuronové sítě - jedná se o speciální matematické algoritmy, jenž dokáží velmi dobře simulovat činnost biologických neuronových sítí a tím i napodobovat inteligenci ve specifických úkolech.
- Robotiku - což jsou v podstatě stroje - počítače ve formě autonomních jednotek, jenž dokáží být v interaktivním kontaktu se svým okolím.

V současné době bohužel zatím neexistuje stroj, který by všechny tyto vlastnosti splňoval.

² Alan Mathison Turing (23. červen 1912 – 7. červen 1954) byl významný britský matematik, logik, kryptograf a zakladatel moderní informatiky. (Zdroj: http://cs.wikipedia.org/wiki/Alan_Turing).

³ John McCarthy (* 4. září 1927, Boston) je americký informatik a kognitivní (poznávací) vědec. V roce 1971 obdržel Turingovu cenu za přínos v oboru umělé inteligence. V roce 1955 navrhl na konferenci v Dartmouthu používat pojem "umělá inteligence", který se všeobecně ujal. John McCarthy je také tvůrce programovacího jazyka LISP. (Zdroj: [http://cs.wikipedia.org/wiki/John_McCarthy_\(informatik\)](http://cs.wikipedia.org/wiki/John_McCarthy_(informatik))).

Existují i další strojové podoby inteligence. Tyto stroje jsou však zatím pouze specialisty na specifické druhy úkolů. Například šachový superpočítač Deep Blue postavený firmou IBM, který v roce 1997 porazil v šachu šachového velmistra světa Gary Kasparova. Na šachy je zřejmě dokonalý, ale jeho programové vybavení se specializací na šachy by asi nedokázalo vykonávat taková rozhodnutí, jako je například rozeznávat hlas.

1.1.2 Další definice umělé inteligence

Další definice umělé inteligence, se kterými se lze setkat, jsou:

- Umělá inteligence je odvětví počítačové vědy, které se zabývá za pomoci strojů řešením různých problémů, tak jak by jej řešil člověk.
- Umělá inteligence je schopnost stroje vykonávat činnost, kterou byl doposud schopen vykonávat jen člověk. Jde o rozhodování, optimalizaci, heuristické řešení problémů, rozeznávání řeči, počítačové vidění a robotiku.
- Umělá inteligence je široký pojem zahrnující komplexní schopnosti, jako je schopnost pracovat s abstraktními symboly, koncepty a vztahy, učení se z vlastních zkušeností a z toho plynoucí adaptabilita, schopnost adaptovat se na nové podmínky tak, aby daný problém byl co nejlépe vyřešen.
- Umělá inteligence je odvětví počítačové vědy, jenž je zaměřeno na simulování inteligentního chování.

Přesto, že definic umělé inteligence je velké množství, jde vždy o definice obecné, které neříkají, co to inteligence doopravdy je. Mnozí vědci na poli umělé inteligence věří a doufají, že k simulování umělé inteligence stačí napsat jen komplikovaný program, i když takové programy mají svá omezení. Nevykazují prvky kreativního chování a navíc jsou úzce specializované.

Výzkum umělé inteligence se dá dělit do dvou směrů, a to do teoretického a experimentálního:

- V teoretické části je studováno jaké intelektuální mechanismy existují a v jaké interakci s řešenými problémy jsou.
- V experimentální části se aplikují různé algoritmy a testuje se jejich způsobilost k řešení specifických úkolů. Tyto úkoly mohou být například rozeznávání řeči, obrazu, nebo také optimalizace cesty vzhledem ke komplikovaným omezením.

Jako příklad problému, jenž se vlastně nedá řešit klasickými metodami, je problém takzvané kombinatorické exploze. V tomto typu úloh se řeší hledání optimální kombinace rozhodnutí existuje-li například 10 úrovní a v každé úrovni 10 možností, pak takový problém představuje 10 miliard možných kombinací. Takové problémy lze řešit v rozumném čase jen pomocí metod umělé inteligence.

I když stále neexistuje komplexní definice umělé inteligence a ani autonomní (nezávislé) inteligentní roboty a androidi, tak existují pravidla, kterými by se tyto stroje měli řídit. Tato pravidla nebyla vyvinuta vědci z oblasti umělé inteligence, ale autorem byl spisovatel Isaac Asimov⁴, který navrhl celkem tři pravidla:

- Zákon první - robot nesmí ublížit člověku, ani svou nečinností dopustit, aby člověku bylo ublíženo.
- Zákon druhý - robot musí uposlechnout příkazů člověka, kromě případů, kdy by uposlechnutí rozkazu bylo v rozporu se zákonem prvním.
- Zákon třetí - robot musí chránit vlastní existenci, pokud tato ochrana není v rozporu s prvním a druhým zákonem.

Tato tři pravidla by měla údajně zajistit, že se inteligentní stroj nikdy nepostaví proti svému tvůrci. Na první pohled tvoří tyto tři zákony robotiky logický komplex, jenž by měl opravdu zajistit bezpečnost člověka a jeho věčnou vládu nad stroji.

Měli by být aplikovány na adaptivní a učící se stroje. Tedy na stroje, které se učí překonávat překážky, učí se z vlastních chyb, provádějí kvalifikovaná řešení atd. Avšak porušení či dokonce ignorování těchto pravidel by se mohlo stát jedním z cílů myslících strojů.

Na tuto možnost poukázal I. Asimov v jednom ze svých románů a přidal další, takzvaný nultý zákon robotiky:

- Zákon nultý - robot nesmí lidstvu ublížit, ani svou nečinností dopustit, aby lidstvu ublíženo bylo.

Předchozí tři zákony bychom mohli přeformulovat do tvaru:

⁴ Isaac Asimov (2. ledna, 1920 v Bělorusku – 6. dubna, 1992 New York, USA) byl americký spisovatel a biochemik. (Zdroj: http://cs.wikipedia.org/wiki/Isaac_Asimov).

- Zákon první - robot nesmí ublížit člověku, ani svou nečinností dopustit, aby člověku bylo ublíženo kromě případů v nichž by takové jednání bylo v rozporu s Nultým zákonem (takže může i zabít, bude-li to nutné).
- Zákon druhý - robot musí uposlechnout příkazů člověka, kromě případů, kdy by uposlechnutí rozkazu bylo v rozporu s Nultým a Prvním zákonem.
- Zákon třetí - robot musí chránit vlastní existenci, pokud tato ochrana není v rozporu s Nultým, Prvním a Druhým zákonem.

Tato změna by pak dala inteligentním strojům do rukou možnost obcházet původní tři pravidla. Rozhodnutí o tom, jestli dodržovat původní tři zákony robotiky, by pak bylo pouze na vůli stroje.

Je jasné, že ony tři zákony robotiky Isaac Asimova rozhodně nestačí. Musí zřejmě tvořit uzavřenou komplexní logickou strukturu, jejíž další modifikace či výměna bude po prvotním spuštění stroje nemožná.

1.2 Co umí umělá Inteligence

Ke kritériím umožňujícím posoudit oprávněnost této vědecké disciplíny na samostatnost, vlastní předmět a jeho hranice patří:

- specifický předmět studia,
- dostatek experimentálního materiálu jako důkaz interakce zkoumané problematiky s vnějším prostředím,
- vlastní metodologické principy a pojmový aparát pro systemizaci a zobecnění zkoumaného materiálu,
- možnost analyzovat a modelovat podstatné zákonitosti zkoumané oblasti.

Umělá inteligence, vědecká disciplína zabývající se reprodukcí vyšší intelektuální činností člověka technickými prostředky.

1.3 Umělá inteligence jako vědní disciplína

Umělá inteligence představuje interdisciplinární obor, neboť může být řešena z různých pohledů psychologů počínaje a matematickými vědami konče.

1.4 Dva pohledy na umělou inteligenci

- Myšlení je předmět zkoumání a stroj je jeho nástrojem. Tento pohled reprezentuje ty, kteří zkoumají podstatu myšlení a počítače představují jejich výkonný nástroj.
- Počítač je předmětem zkoumání a myšlení je jeho model. Tento přístup vyjadřuje snahu o vytvoření inteligentních strojů jako cíl zkoumání v oblasti umělé inteligence. Chování lidského myšlení pak slouží jako jejich model.

1.5 Umělá inteligence - zatím vzdálený sen⁵

Počítače, byť supervýkonné, však dosud mají pouze směšný výkon v porovnání s mozkem. Projekt Blue Brain⁶ bude v počáteční fázi pracovat se zmíněnými 8 tisíci procesory, přičemž každý simuluje jeden neuron a je pravděpodobné, že se bude časem jeho výkon zvětšovat. Lidský mozek však obsahuje miliardy neuronů.

Abychom se tedy přiblížili těmto parametrům, budeme si ještě muset hezkou chvíli počkat. Problém však není jen ve výkonu, vědci musí rovněž dobře poznat, jak jsou vazby mezi miliony neuronů tvořeny a jak mají tím pádem pospojovat jednotlivé procesory či počítače. Ani to však ještě není ten největší problém. Nikdo v současné době neví, co to vlastně je vědomí a odkud se objeví. Můžeme mít simulaci milionů neuronů a jejich spoju a vědět jak fungují, ale vědomí nasimulovat dodnes neumíme. Stále totiž nevíme, co to vlastně je.

Než tedy získáme věrný model celého mozku (o umělé inteligenci ani nemluvě), bude to ještě dlouhá cesta. V první fázi projektu Blue Brain se budou provádět simulace na buněčné úrovni a to potrvá dva až tři roky. Další fáze budou následovat. Na umělou inteligenci si tak ještě nějaký čas počkáme.

⁵ Zdroj: <http://www.zive.cz/Clanky/Pomuze-nam-superpocitac-odhalit-tajemstvi-mozku/sc-3-a-126381/default.aspx> - dostupný dne 20. ledna 2009

⁶ Projekt Blue Brain (Modrý mozek) – Projekt s využitím superpočítače firmy IBM (eServer Blue Gene Solution s výkonem: 18,2 teraflops), který by měl pomoci zmapovat lidský mozek a vytvořit trojrozměrný obraz neokortexu, což je největší a nejkompexnější část mozku, v níž se odehrávají procesy řeči, učení nebo paměti. (Zdroj: <http://www.21stoleti.cz/view.php?cisloclanku=2005111807>).

1.6 Lidský mozek má výkon 38 petaflops a paměť 3 581 TB⁷

Podle Dharmendry Modhy, šéfa výzkumného týmu z IBM Almaden Research Center, který se zabývá problematikou umělé inteligence a tvorby kybernetického mozku, je zatím skutečná umělá inteligence kdesi v mlhavém nedohlednu. Jeho tým získal v roce 2008 pětimilionový grant od americké agentury DARPA na projekt SyNAPSE. Jeho účelem bylo reverzním inženýrstvím zjistit techniky lidského mozku, které by pak bylo možné aplikovat i v běžných softwarových výpočtech.

Po několika měsících už má Dharmendry Modha jasno. Ačkoliv jsou superpočítače stále rychlejší, zatím jen z velké dálky pokukují po výkonu zcela běžného mozku. Tradiční počítač by totiž musel mít 3 581 terabajtů paměti a výkon okolo 38 petaflops (38 biliard operací za sekundu). Jen pro srovnání, současný nejrychlejší počítač světa disponuje výkonem 1 petaflops a na rok 2011 plánuje IBM sestavit pro americkou vojenskou laboratoř Lawrence Livermore v Kalifornii cluster s výkonem 20 petaflops.

Podle Dharmendry Modhy bychom se mohli dočkat srovnatelného výkonu jako lidský mozek někdy okolo roku 2018, kdy, jak sám předpovídá, bude schopen člověk alespoň na elementární úrovni simulovat skutečný mozek.

Jen pro srovnání, pokud vezmeme v potaz Modhův výpočet, český nejrychlejší superpočítač Amálka je 9500krát pomalejší než nejobyčejnější šedá kůra mozková

⁷ <http://www.zive.cz/Bleskovky/Lidsky-mozek-ma-vykon-38-petaflops-a-pamet-3-581-TB/sc-4-a-146110/default.aspx> - dostupný dne 13. března 2009.

Flops (floating point operations per second) = počet operací za sekundu; jednotka se používá k měření rychlosti procesorů využívaných pro vědecké účely. Jeden teraflop odpovídá zhruba stonásobně vyšší výpočetní rychlosti, než které dosahují nejrychlejší stolní počítače. (Zdroj: <http://www.21stoleti.cz/view.php?cisloclanku=2005111807>).

Obr. 1: Tabulka srovnání počítač versus lidský mozek

| | Počítač | Lidský mozek |
|---------------------------|--|--|
| Výpočetní jednotka | 1 CPU | 10^{11} buněk |
| Paměť | 10^9 bitů RAM 10^{11} bitů na disku | 10^{11} neuronů 10^{14} synapsí |
| Délka cyklu | 10^{-8} sekundy | 10^{-3} sekundy |
| Šířka pásma | 10^9 bitů za sekundu | 10^{14} bitů za sekundu |
| Rychlost obnovy | 10^9 výpočetních elementů | 10^{14} neuronů za sekundu |

Zdroj: Presentace, Umělé neuronové sítě z pohledu rozpoznávání, Václav Hlaváč, Centrum strojového vnímání, Katedra kybernetiky FEL ČVUT. Dostupná z <http://cmp.felk.cvut.cz/~hlavac/TeachPresCz/31Rozp/72UmeleNN.pp> - dne 15. ledna 2009

2 Vývoj a současný stav umělé inteligence

Kapitola popisuje shrnutí podstatných historických událostí zrodu myšlenky umělé inteligence a jejím využitím v současné době.

2.1 Minulost umělé inteligence

Umělá inteligence je vědecká disciplína zabývající se postupy pro konstrukci programů a zařízení, jejichž činnost, kdyby ji vykonával člověk, považujeme za projev lidské inteligence. V nejširším měřítku se na modelování lidské činnosti zaměřila kybernetika. Její zakladatel N. Wiener ji kolem roku 1947 definoval jako nauku o sdělování a řízení v živých organismech a strojích. Kybernetika se v počátku zabývala zpětnovazebními procesy, přenosem informace, teorií systémů, teorií řízení a mnoha dalšími disciplínami. Za model centrální nervové soustavy kybernetika považovala logické obvody a neuronové sítě. Tyto originální myšlenky a postupy vytvořily základ nových disciplín, ležících mezi logikou, programováním a psychologíí a které souborně nazýváme umělou inteligencí.

Rokem vzniku umělé inteligence je považován rok 1956. John McCarthy tehdy v Dartmouth College zorganizoval konferenci, která měla pojem umělá inteligence v samotném názvu - The Dartmouth Summer Research Project on Artificial Intelligence. Na konferenci předvedli pánové Newel a Simon fungující inteligentní program pro dokazování teorémů (pravdivých, platných tvrzení).

Další projekt GPS (General Problem Solver), systém pro řešení téměř jakékoliv úlohy, byl před dokončením. I když nadšenci, zabývající se v druhé polovině padesátých let umělou inteligencí, patřili k vědeckému disentu (seskupení stoupenců jiného smýšlení), byly dokončeny první šachové programy, úspěšný program na hraní dámy, programy na dokazování teorémů a také vznikly speciální jazyky pro umělou inteligenci. Jako je například program LISP (LISt Processing). Entuziasmus při vzniku nové vědecké disciplíny charakterizuje předpověď H. Simona v roce 1957 na konferenci Společnosti pro operační výzkum. H. Simon předpokládal, že do deseti let bude počítač mistrem světa v šachu, vytvoří hudební skladbu výrazné estetické hodnoty, dokáže důležitý matematický teorém a rovněž většina psychologických teorií bude mít podobu počítačových programů. Prognóza, která se samozřejmě nenaplnila, je považována za důkaz nadšení a optimismu konce padesátých let.

2.2 Současnost umělé inteligence

Umělá inteligence prochází dlouhodobě procesem diferenciací. Rozdělila se do zhruba tří desítek navzájem zdánlivě nesouvisejících disciplín. K nejznámějším patří:

- přirozené a umělé myšlení jako filozofický problém,
- řešení úloh, dokazování vět a využívání znalostí,
- reprezentace znalostí a modelování,
- rozpoznávání a učení,
- plánování,
- neuronové sítě,
- analýza, syntéza a rozpoznávání mluvené řeči,
- zpracování přirozeného jazyka,
- počítačové vidění,
- znalostní inženýrství,
- distribuovaná umělá inteligence,
- programovací prostředky umělé inteligence,
- evoluční metody, samoreprodukce a umělý život,
- multiagentní systémy,
- matematické teorie umělé inteligence včetně teorie složitosti,
- aplikovaná umělá inteligence a expertní systémy.

Aplikovaná umělá inteligence a expertní systémy si zaslouhují pozornost. Znalostní a expertní systémy jsou počítačové programy, simulující rozhodovací činnost experta při řešení složitých úloh. Expertní systémy využívají obecných i speciálních znalostí, převzatých od skupiny expertů s cílem dosáhnout ve zvolené problémové oblasti kvality rozhodování na úrovni experta. Expertní systémy využívají metod vyvinutých v umělé inteligenci, která tvoří styčnou oblast mezi kybernetikou, logikou a psychologií. Z hlediska charakteru řešených úloh lze existující expertní systémy rozdělit do tří skupin. Do diagnostické, plánovací a hybridní. Z hlediska aplikací jsou dnes expertní systémy využívány k řešení nejrůznějších úloh. Například typu analytického jako je lékařská

a technická diagnostika, klasifikace a interpretace dat, identifikace systémů a analýza složitých signálů. Dále pak typu syntetického to jsou technické návrhy, plánování, návrhy terapie v medicíně, návrhy zákonů a vyhlášek. I typu hybridního kde je výuka a monitorování.

Po roce 1981 nastala etapa komerčně dostupných expertních systémů (ECON, XSEL, DIPMETER, ADVISOR a mnoha dalších). Za zmínku stojí expertní systém CADUCEUS, který podle expertů obsahuje až 85 procent veškerých znalostí z interního lékařství. Jedním z mnoha prázdných expertních systémů, které vznikaly a vyvíjely se za posledních dvacet let, je CLIPS, což je zkratka pro C Language Integrated Production System. I když byl CLIPS vyvinut v Johnson Space Center (oddělení umělé inteligence NASA) a představen zájemcům už v roce 1986, prošel dlouhým vývojem. Je pro svou jednoduchost a mnohostranné využití velmi oblíben v průmyslových, armádních i akademických kruzích.

Další etapu vývoje expertních systémů představuje systém G2 společnosti Gensym Corporation. Tento expertní systém je využíván při nejrůznějších aplikacích, například v jaderné elektrárně Forsmarkverket ve Švédsku, při udržování stability výrobků papírny Norsko Skogindustier v Norsku, při výzkumu raketových paliv firmy Lockheed i optimalizaci spotřeby paliva motorů vesmírných raketoplánů v NASA.

Systém G2 byl a je velmi známým a úspěšným produktem firmy Gensystem Corporation; firma měla přibližně sedmiprocentní podíl světového trhu umělé inteligence a zaujímala šesté místo na světě. I když se cena jedné licence pohybuje mezi 9.000 až 44.000 USD, podle údajů z roku 1995 bylo prodáno více než 5000 licencí do 40 států světa.

Zdá se, že schopnost aplikovat umělé inteligentní systémy je charakteristická pro jakoukoliv dynamickou organizaci. Údajně již každá z 500 nejúspěšnějších amerických firem zavedla některou z forem umělé inteligence jako součást firemní kultury.

3 Kategorizace umělé inteligence

Kategorizace umělé inteligence zde představuje nejznámější systémy využívané tímto odvětvím, jejich využití a jakým způsobem se využívá v průmyslovém odvětví.

3.1 Umělá inteligence není jen pouhý slovní výraz

O umělé inteligenci se hovoří již od začátku vývoje počítačů. V očích veřejnosti jde však stále o zcela imaginární věc, ke které se lidstvo blíží neznatelným tempem. Není totiž všeobecně známo, že inteligentní systémy jsou již dávno v praxi a to i v České republice.

Obecně je umělá inteligence věda, která se zabývá vkládáním lidské inteligence strojům. Tedy lépe řečeno počítačům. Taková je obecná definice, která je srozumitelná všem pokročilým uživatelům počítačů. Umělá inteligence je ale poměrně obsáhlým vědním oborem, který se dále dělí na řadu dalších podkategorií.

Těmi hlavními podkategoriemi jsou Expertní systémy, Genetické algoritmy a v neposlední řadě také Neuronové sítě.

3.1.1 Expertní systémy

Expertní systémy jsou počítačové aplikace, které mají za úkol poskytovat expertní rady, rozhodnutí nebo doporučit řešení v konkrétní situaci. Expertní systémy musí být navrženy tak, aby mohly zpracovávat nenumerné a neurčité informace a řešit tak úlohy, které nejsou řešitelné tradičními algoritmickými postupy. Expertní systémy mají dva základní moduly, které jsou na sobě víceméně nezávislé. Řídící mechanismus pro odvozování závěrů a bázi znalostí. Znalosti poskytují podklady pro rozhodnutí řídicího algoritmu.

Typické příklady využití:

- pomáhá uživatelům získat znalosti,
- specializace na expertní záležitosti,
- pomáhá organizovat úlohy (obvykle se využívá v průmyslových aplikacích)

3.1.2 Genetické algoritmy

Genetické algoritmy využívají heuristickou metodu, kterou se snaží za pomoci aplikace principů evoluční biologie nalézt řešení složitých problémů, pro které neexistuje použitelný exaktní algoritmus. Genetické algoritmy používají napodobující evoluční procesy známé z biologie jako jsou dědičnost, mutace, přirozený výběr či křížení. Účelem je šlechtění řešení zadané úlohy. Princip práce genetického algoritmu je postupná tvorba generací různých řešení daného problému. Při řešení se uchovává tzv. populace, jejíž každý jedinec představuje jedno řešení daného problému. Jak populace probíhá evoluci, řešení se zlepšují.

Typické příklady využití:

- průmyslové úlohy – dělení materiálu,
- předpověď budoucího vývoje,
- statistické metody


3.1.3 Neuronové sítě

Neuronová síť je soustava propojených neuronů. Neuronové sítě vycházejí z přírodního schématu. Osvědčily se v těch nejsložitějších biologických systémech určených k přežití v jejich řízení. Obecně vzato jsou neuronové sítě černé krabice, do kterých se pouští data na vstup a na výstupu vycházejí data již zpracovaná, závislá na datech vstupních. Základní vlastností a výhodou neuronových sítí je jejich schopnost učit se z příkladů. Neurony v počítači jsou reprezentovány matematickými modely biologických neuronů.

Typické příklady využití:

- ekonomické informační systémy,
- technické systémy,
- zdravotnictví

Obr. 2: Biologický neuron pod mikroskopem



Zdroj: <http://www.dsl.cz/clanky-dsl/clanek-706/umela-inteligence-neni-jen-planym-zvolanim>. Dostupný dne 15.1.2009

3.2 Jaká je praxe v českých poměrech

V českých poměrech se s umělou inteligencí setkáte nejčastěji na průmyslovém poli a je výsadou jen několika málo firem. Obvykle jde o průmyslové implementace informačních a optimalizačních systémů. V českých podmínkách se ujala například optimalizace tyčového materiálu, kde je prognózováno řezání tyček tak, aby byly zbytky materiálu co nejmenší. Další aplikací je například efektivní naplnění pecí v ocelárnách. Při realizaci je větším problémem zrychlení pomalých genetických algoritmů, což se provádí pomocí navazujících algoritmických postupů. Kombinací obecných evolučních metod s expertními heuristikami bylo dosaženo rychlosti, která umožňuje nasazení těchto systémů k řízení v reálném čase nebo k optimalizaci desetitisíců položek s přiměřenou odezvou, při současném dosahování vysokých úspor provozních nákladů, což je v oblasti genetické optimalizace výjimkou.

Využití umělé inteligence je v průmyslovém prostředí stále více aktuální, neboť majitelům průmyslových podniků ušetří nemalé náklady na materiál a služby spojené s výrobou. Majitelé podniků jsou ochotni zaplatit i statisíce za vývoj podobných aplikací, neboť návratnost je často v řádech týdnů.

4 Neuronové sítě

Neuronové sítě se stále vyvíjí a jejich využití se stále více aplikuje v různých odvětvích našeho života. Kapitola nás seznámí s jejich původem, se základními pojmy, s jakými typy těchto sítí se můžeme setkat, jakým způsobem pracují a v jaké oblasti se dají využít. V závěru kapitoly je pak návrh dalšího možného využití neuronových sítí v ekonomické sféře podniku.

4.1 Specifika neuronových sítí

Umělé neuronové sítě dominují v rozpoznávání okamžité závislosti ze vzorů vstupně-výstupních vztahů. Tím se liší od expertních systémů, které dosahují výborných výsledků v posloupnosti logických operací a fuzzy logických metod, které se vyznačují schopností reprezentovat znalosti.

Neuronové sítě jsou inspirovány biologickými neuronovými sítěmi. Tato vlastnost určitým způsobem předurčuje, že uměle vytvořené neuronové sítě by měly být schopny, z hlediska základních principů, se chovat stejně nebo alespoň podobně jako jejich biologické vzory. Vytvoření umělého lidského mozku se všemi jeho schopnostmi je však věc jen velmi těžce řešitelná ať už z hlediska kvantity jeho neuronů či jejich způsobu propojení nebo chování jednotlivých typů neuronů.

Neuronové sítě využívají distribuované, paralelní zpracování informace při provádění výpočtů. To znamená, že ukládání, zpracování a předávání informace probíhá prostřednictvím celé neuronové sítě než pomocí určitých paměťových míst. Paměť a zpracování informace v neuronové síti je ve své přirozené podstatě spíše globální než lokální.

Znalosti jsou ukládány především prostřednictvím síly vazeb mezi jednotlivými neurony. Vazby mezi neurony vedoucí ke správné odpovědi jsou posilovány a naopak, vazby vedoucí k špatné odpovědi jsou oslabovány pomocí opakované expozice příkladů popisujících problémový prostor.

Topologie učení je základní a podstatná vlastnost neuronových sítí. Tento fakt zjevně vyjadřuje základní rozdíl mezi dosud běžným použitím počítačů a použitím prostředků na bázi neuronových sítí. Jestliže jsme doposud veškeré své úsilí při tvorbě uživatelských

programů soustředili na vytvoření algoritmů, které transformují vstupní množinu dat na množinu dat výstupních, pak neuronové sítě již tuto náročnou fázi nepotřebují. Jakým způsobem se budou vstupní data transformovat na data výstupní, určuje právě fáze učení založená na již dříve uvedené expozici vzorků nebo příkladů popisující řešenou problematiku - trénovací množina. Odpadá tedy nutnost algoritmizace úlohy, která je nahrazena předložením trénovací množiny neuronové sítě a jejím učením.

4.2 Vývoj neuronových sítí

První informace o neuronových sítích bývá spojována se jmény McCullocha a Pittse, kteří sestavili první neuronový model. V roce 1949 navrhl Donald Hebb model založený na biologické podobnosti, který je schopný učení. Na popsáných principech je založena řada moderních učících se síťových mechanismů. Dominantní postavou 50. let 20. století se v oblasti neuronových sítí stal Frank Rosenblatt. Vyvinul třídu neuronů označovaných jako perceptrony. Jeho přístup výrazně posunul vpřed teorii založenou na rozpoznávání vzorů a asociativním učením. Na přelomu 60. a 70. let pokračovala intenzivně ve vývoji neuronových sítí řada vědců. K nejznámějším patří Steven Grossberg, Geoffery Hinton, Teuvo Kohonen, Kunihiro Fukushima a J. A. Anderson.

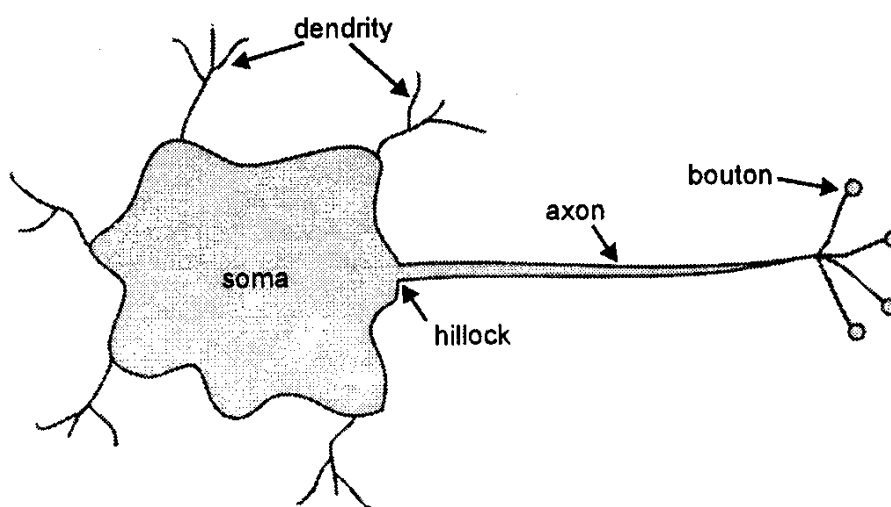
V roce 1982 publikoval John Hopfield, profesor chemie a biologie z Technologického institutu v Kalifornii, články o neuronových sítích, které inspirovaly řadu vědců a roztočily další kolo rozvoje neuronových sítí. Objevilo se v nich několik klíčových momentů, jako popis zpětné vazby mezi neurony, nelinearita přenosových funkcí, koncept globální energetické funkce, teorie energetických stavů a teorie minimalizace energetického toku. V roce 1986 napsal Rumelhart se svým kolektivem první knihu o neuronových sítích. V témže roce se objevily první aplikace teorie zpětného šíření (backpropagation) při učení neuronových sítí, které byly popsány v článku Sejnowského. V roce 1992 bylo vyvinuto první hardwarové řešení neuronových sítí - neuronové karty (LORAL - USA), které se vkládají do počítače. Hardwarové řešení urychlilo proces učení až více než tisíckrát. V roce 1993 se objevily obdobné komerčně dostupné hardwarové karty (CNAPS), vyvinuté firmou Adaptive Solution rovněž z USA, které je možné využít jako akcelerator při trénování neuronových sítí.

V naší odborné veřejnosti lze zaznamenat první články a publikace s obecným popisem neuronových sítí až po roce 1988. Z autorů můžeme vybrat například Hořejše a Kufudaki, Nováka, Bílu a Křivana.

4.3 Základní pojmy

Pro pochopení funkce neuronové sítě je třeba si uvědomit některé základní pojmy. Lidský mozek sestává ze sítě mnoha bilionů speciálních buněk, které se nazývají neurony.

Obr. 3: Model biologického neuronu




Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

Typický neuron znázorněný na obrázku (Obr. 3: Model biologického neuronu.) se skládá z těla neuronu (soma), z něhož vybíhá nervové vlákno (axon). To je zakončené rozvětvením směřujícím k ostatním neuronovým buňkám v síti, s jejichž těly tvoří elektrochemickou vazbu (synapse).

Dendrity, které spojují neuron s ostatními pomocí synapsí, přenášejí podráždění (vstupní signály) do somy. Zde jsou tyto signály sečteny a je rozhodnuto podle jejich síly a povahy, zda budou propuštěny a s jakou silou (filtrace přes membránu - hillock) do axonu. Ten pak přenáší signál do ostatních neuronů přes boutony s různou velikostí a zpožděním. Každá neuronová buňka se chová jako extrémně jednoduchý počítač, jehož schéma je uvedeno na obrázku (Obr. 4: Model umělého neuronu)

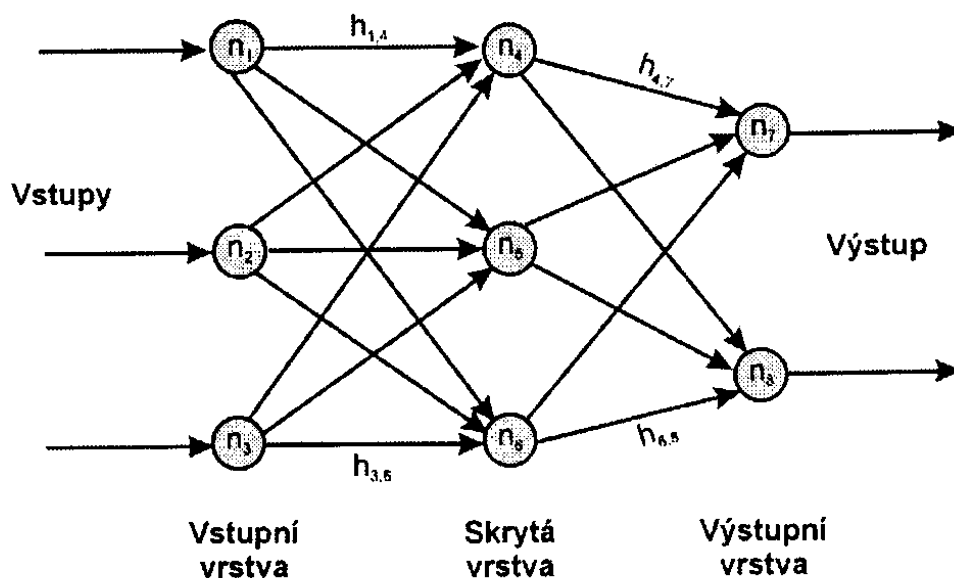
Obr. 4: Model umělého neuronu



Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

Umělý neuron přijímá vstupní signály (vstupy) a vysílá výstupní signál (výstup). Každý neuron přijímá vstupy z mnoha jiných neuronů. Umělou neuronovou síť definujeme jako orientovaný graf $G(N, H)$, ve kterém množinu vrcholů N tvoří těla neuronů n_i a množinu hran H tvoří spojnice neuronů $h_{i,j}$. V tomto grafu jsou jednotlivé neurony uspořádány do vrstev podle následujícího obrázku (Obr. 5: Umělá neuronová síť)

Obr. 5: Umělá neuronová síť



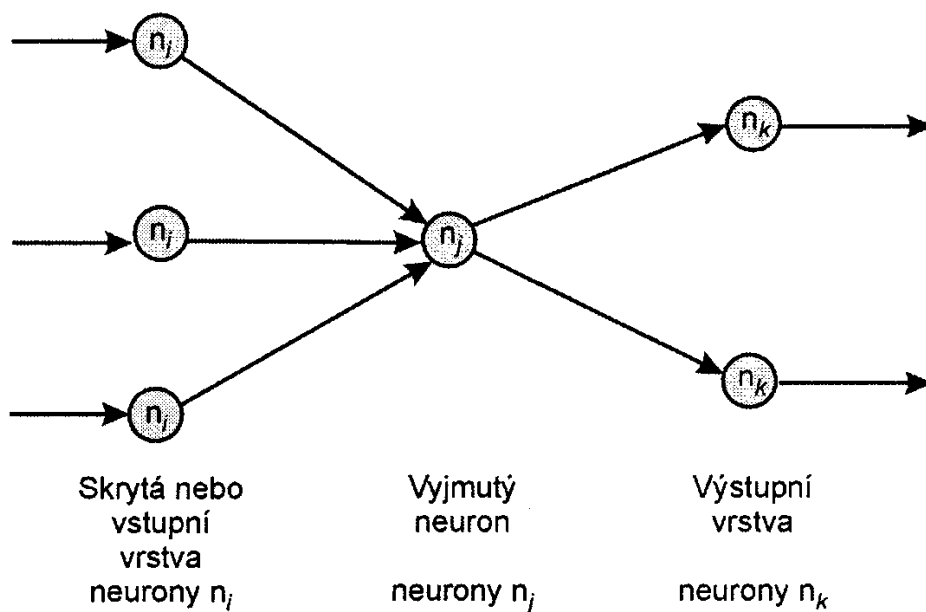
Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

tak, že vstupní vrstvu tvoří vstupní neurony, dále následuje skrytá vrstva neuronů (může být více vrstev) a vrstva výstupních neuronů. Neurony jsou v neuronových sítích průběžně

očíslovány. Každý neuron v libovolné skryté vrstvě je spojen hranou s každým neuronem vrstvy předchozí i vrstvy následné.

Funkci typického neuronu v umělé neuronové síti je možné popsat na příkladu neuronu n_j vyjmutého ze skryté vrstvy, který je znázorněn na dalším obrázku (Obr. 6: Neuron n_j vyjmutý ze skryté vrstvy).

Obr. 6: Neuron n_j vyjmutý ze skryté vrstvy



(Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004)


Zde jsou současně zobrazeny tři neurony n_i z předchozí vrstvy, které mu signál předávají, a symbolicky dva neurony n_k z následující výstupní vrstvy, které od něj signál přijímají. Označme u počáteční a v koncové číslo neuronu n_i předávajícího signál neuronu n_j podle průběžného číslování neuronů v neuronové síti.

Umělá neuronová síť a signál tedy postupuje pouze jedním směrem - zleva doprava, mluvíme o jednosměrných neuronových sítích (feed-forward networks). Pokud signál vstupuje do neuronů současně i zprava směrem doleva, nazývá se neuronová síť zpětnovazební (feed-back networks). Podle autorů nebo uspořádání byla nazvána řada typických modelů sítí: Hopfieldova, BAM, ART, Perceptron, Kohonenova atd.

Jako přenosové funkce se v umělých neuronových sítích používají tyto typy funkcí:

- Logistická sigmoidální funkce (sigmoida):

Obr. 7: Sigmoida




Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

Je nelineární, spojitá a spojitě diferencovatelná a má tudíž mnoho žádoucích vlastností, vhodných pro využití v neuronových sítích.

- Skoková přenosová funkce. Funkce je limitována dvěmi možnými hodnotami. Středem je vždy hodnota vstupu, při kterém se hodnota výstupu skokem změní:

Obr. 8: Skoková přenosová funkce




Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

Vzhledem k nespojitosti je nelineární funkcí. Je vhodná zejména do aplikací, ve kterých neurony v neuronové síti fungují jako přepínače. Tyto typy funkcí byly často využívány v počátečních aplikacích neuronových sítí.

- Lineární prahová funkce. Neuronové sítě, které ji používají, jsou schopny aproximovat (přiblížit) značně složitější vstupně-výstupní vztahy než lineární neuronové sítě:


Obr. 9: Lineární prahová přenosová funkce



Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

- Gaussova přenosová funkce. Gaussovy přenosové funkce jsou známé jako zvonové funkce. Jejich užití je však dosti omezené. Tato funkce je spojitá a spojitě diferencovatelná. Proto může být využívána stejně jako sigmoida. Poskytuje však velmi nezvyklé a nekonzistentní výsledky. Oblasti jejího užití jsou zatím předmětem výzkumu:

Obr. 10: Gaussova přenosová funkce



Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

4.4 Neuronové sítě - učení

4.4.1 Jak neuronová síť funguje

Jeden ze základních předpokladů pro funkci sítě je její naučení - adaptace na daný problém. Učící proces se skládá ze dvou fází - adaptační a aktivační, během kterých se nastavují již zmíněné váhy sítě. Tento učící algoritmus pracuje s tzv. třídami informací, kde se třídou rozumí množina, která zahrnuje X jedinců se společnou vlastností.

Nově vytvořenou, ale také jakoukoliv nenaučenou neuronovou síť, lze považovat za jakéhosi technického novorozence, který nic neumí. Neumí rozeznávat ani klasifikovat. Aby se mohla používat, musí být naučena stejně jako kterýkoliv živý. Proto byly vyvinuty algoritmy, pomocí kterých se příslušná síť dokáže naučit na danou množinu informací. Algoritmus se tedy dělí na dvě fáze:

- aktivační (vybavovací),
- adaptační (učící),

kteří ke své činnosti potřebují trénovací množinu.


Trénovací množina je skupina vektorů (množina dat), obsahujících informace o daném problému pro učení. Pokud se učí síť s učitelem, pak jsou to dvojice vektorů vstup - výstup. Jestliže se učí síť bez učitele, pak trénovací množina obsahuje jen vstupní vektory. Pokud je používána jen fáze aktivační, pak se mluví o vybavování. Tato fáze je používána samostatně jen tehdy, když je síť naučena. Cyklické střídání obou fází je tedy vlastní učení. Aktivační fáze je proces, při kterém se předložený vektor informací na vstup sítě přepočítá přes všechny spoje včetně jejich vynásobení vahami až na výstup, kde se objeví odezva sítě na tento vektor ve formě výstupního vektoru. Při učení se tento vektor porovná s vektorem originálním (požadovaným výstupním) a rozdíl mezi oběma vektory (lokální odchylka - chyba) se uloží do paměťové proměnné.

Adaptační fáze je proces, při kterém je minimalizovaná lokální chyba sítě tak, že se přepočítávají váhy jednotlivých spojů směrem z výstupu na vstup za účelem co největší podobnosti výstupní odezvy s originálním vektorem.

Poté se opět opakuje aktivační fáze. Další získaný rozdíl (lokální odchylka) se přičte k předchozímu. Pokud se tímto postupem projde celá trénovací množina, je hotova jedna

epocha. Celé sumě odchylek za jednu epochu se říká globální odchylka - chyba. Pokud je globální odchylka menší než požadovaná chyba, pak proces učení skončí. Proces učení tedy není nic jiného, než přelévání informací ze vstupu na výstup a naopak. Při učení se ve vstupním prostoru vytvářejí shluky bodů, které představují jednotlivé členy tříd (jablka, hrušky, kola a jiné), přičemž každý shluk představuje jednu třídu.

Obr. 11: Nelineární hranice mezi třídami - ideální případ (žádný z členů tříd A, B a C neleží v prostoru druhé třídy).



Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003

Pokud tedy existuje například několik tříd, a to třída kol, aut, lodí atd., pak lze provést naučení sítě. Z každé třídy je vybrána množina reprezentativních zástupců (vzorů pro učení) a ti jsou popsáni vhodným číselným způsobem ve formě vektorů. Pro každou množinu vektorů jedné třídy je pak vytvořen vzorový vektor, který bude zastupovat mateřskou třídu z reálného světa. V tu chvíli existují vytvořené skupiny vektorů popisující jednotlivé členy a jim příslušející představitele tříd ve formě vektorů. Například existují vektory, které popisují vybrané členy z třídy kol a vektor, který říká: já jsem třída kol. V tomto případě učení znamená to, že se učící algoritmus snaží najít takovou kombinaci vah, která umožní přiřazení vektoru třídy jejím členům. Jinak řečeno, hledá se taková kombinace vah, že pokud bude položen ve vybavovací fázi na vstup vektor popisující

objekt např. kolo, pak by se na výstupu měl objevit vektor, který říká: já jsem třída kol, nebo můžeme říci, že daný vstupní vektor patří do třídy kol.

Existuje-li tedy například 5 různých tříd a z každé třídy 20 reprezentativních členů, představuje to celkem 100 vstupních vektorů. Při učení se hledají takové váhy, aby odezva sítě pro daný vstupní vektor (člen) byla co nejvíce podobná vektoru jeho třídy. Vzhledem k tomu, že se neuronová síť učí vždy s nějakou chybou, nebude odezva vždy přesně odpovídat originálu. Tím pak vznikne shluk bodů okolo pozice originální třídy.

To, zda se síť naučí správným odezvám na dané podněty, závisí na více okolnostech. Na množství vektorů a jejich velikosti, topologii sítě, odlišnosti charakteristických vlastností jednotlivých tříd, přípravě trénovací množiny a mnoha dalších. Schopnost sítě přiřazovat jednotlivé vstupní členy daným třídám je daná tím, že síť v podstatě počítá vzdálenost daného členu od členů již přiřazených, a na základě toho usuzuje, do jaké třídy daný vektor patří.

4.4.2 Neuronové sítě a regresní modely

Mezi neuronovými sítěmi a regresními modely lze nalézt analogii. Zejména vícerozměrný lineární regresní model připomíná svým tvarem vztah pro výstupní neuron jednosměrné lineární neuronové sítě s jedinou vrstvou vstupních neuronů, s jediným výstupním neuronem a s nulovým prahem u všech neuronů.

Je zřejmé, že lze sestavit neuronové sítě, které mohou nahradit i vícerozměrné nelineární regresní modely. Jde například o polynomické regresní modely, mocninné regresní modely i další velmi složité typy regresních modelů. Srovnáním obou typů modelů se zabývala řada autorů. John Searle⁸ například uvádí:

"Výzkumníci z oboru neuronových sítí znovu vynalezli metody známé ze statistické nebo matematické literatury desetiletí či století, ale často nechápou, jak tyto metody fungují". Částečně je možné s tímto názorem souhlasit. Neuronové sítě a regresní modely mají mnoho společného. Zejména to však platí pro velmi jednoduché jednosměrné vícevrstvé neuronové sítě. Značným problémem u vícerozměrných nelineárních úloh je volba vhodného tvaru regresní rovnice. Tyto vztahy se nedají znázornit jednoduchým grafem

⁸ John Rogers Searle (* 31. července 1932 Denver, Colorado) je americký filosof a profesor filosofie na University of California v Berkeley, který významně přispěl k rozvoji filosofie jazyka a řečových aktů. V roce 1980 předložil Argument čínskému pokoje. V roce 2000 získal cenu Jean Nicod Prize. (Zdroj: http://cs.wikipedia.org/wiki/John_Searle)

a řešitel často sklouzne do oblasti intuitivní a uvedený problém řeší metodou pokusů a omylů. Opřít se tu může jenom o své zkušenosti z předchozích prací, literaturu a zkušenosti svých kolegů.

Samostatným problémem je kalibrace nelineárního regresního modelu (výpočet regresních koeficientů). Řešitel musí být dobře obeznámen s nelineární optimalizací a musí mít k dispozici adekvátní software umožňující tuto operaci provést. Problémem je i volba kritéria, podle kterého bude kalibrace provedena. Ta má pro způsob pro ložení regresní křivky množinou bodů rozhodující význam. Pokud pro tento účel použijeme komerční software, dostaneme se do pasti nabídky tvaru regresních funkcí, která nemusí být postačující.

Výhody neuronových sítí oproti regresním modelům je možné shrnout do následujících bodů:

- Neuronové sítě nevyžadují volbu regresní závislosti. Vyžadují pouze volbu počtu skrytých vrstev, počtu neuronů v těchto vrstvách a volbu tvaru přenosových funkcí. Při určitých zkušenostech s jejich použitím však lze tyto volby provést rutinně. Navíc lze vícevrstvé nelineární neuronové sítě použít k aproximaci téměř libovolné nelineární funkce. Stávají se tak univerzálními aproximátory.
- Učení (trénink) neuronové sítě je analogickým termínem pro kalibraci regresního modelu. Neuronové sítě jsou však v procesu učení mnohem obecnější, samy si vyberou, kterému vstupu a parametru mají určit větší váhu a optimalizují větší počet parametrů.
- Neuronové sítě mohou obsahovat více výstupů, jejichž hodnotami odpovídají na zadané hodnoty vstupů, což je pro běžné regresní modely nedostižné.

Pro jednoduché úlohy se tedy lépe hodí použít klasické statistické regresní modely. Technika kalibrace těchto modelů je dostatečně propracovaná. Navíc umožňuje určit meze spolehlivosti, konfidenční (důvěryhodný) interval a řadu dalších důležitých údajů, jejichž určení se u komerčních softwarů, modelujících neuronové sítě, vyskytuje jen zřídka.

Pro složitější úlohy z oblasti vícerozměrné nelineární regrese je však vhodnější použít neuronové sítě, zejména pokud požadujeme souběžně více výstupů. Hodně však záleží na názorech a zkušenostech řešitele a na dostupnosti použitelného softwaru. Řešitel se sám musí rozhodnout, jakou technologii pro řešení zvolí.

4.4.3 Způsob učení (trénování)

Když je dána tréninková matice \mathbf{A} , ve které jsou do určitých sloupců zapsány hodnoty vstupních signálů a do zbývajících hodnoty výstupních signálů. Vždy jeden řádek odpovídá jednomu vztahu mezi vstupem a výstupem - tvoří jeden vzor. Schéma je znázorněno v tabulce níže:

Obr. 12: Schéma tréninkové matice

| | ↓ | ↓ | ↓ | ↓ | ↑ | ↑ |
|-----|-------|-------|-------|-------|-------|-------|
| i | X_1 | X_2 | X_3 | X_4 | Y_1 | Y_2 |
| 1 | 0,4 | 12,7 | 5,1 | 26,5 | 6,8 | 0,0 |
| 2 | 0,8 | 15,6 | 3,8 | 21,7 | 3,3 | 0,2 |
| 3 | 0,6 | 11,1 | 4,3 | 29,6 | 4,4 | 0,5 |
| . | . | . | . | . | . | . |
| . | . | . | . | . | . | . |
| n | 0,3 | 8,5 | 3,7 | 18,9 | 5,1 | 0,4 |

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEŽULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

Vstupní veličiny X_1 , X_2 , X_3 a X_4 jsou zapsány do vstupních sloupců označených symbolem ↓, výstupní veličiny Y_1 a Y_2 jsou pak uvedeny ve sloupcích výstupních, označených symbolem ↑. Číslo uvedené v řádku i udává pořadí příslušného vzoru.

V průběhu učení (trénování) vstupují postupně (po řádcích) do neuronové sítě vstupní signály (tréninkové vzory). V závislosti na velikostech vah a prahů pak vystupují z výstupních neuronů hodnoty výstupních signálů. Postup se opakuje podle počtu řádků tréninkové matice. Zadané výstupní signály a signály vypočtené z neuronové sítě vykazují odchylku. Součet čtverců těchto odchylek vypočtený pro každý vzor zvlášť je chybou vzoru E_v . Součet chyb vypočtených ze všech vzorů je celková chyba E . V procesu trénování se hledají takové hodnoty vah, aby pro všechny řádky tréninkové množiny tyto odchylky nepřekročily povolenou toleranci.

Trénování neuronové sítě představuje současně pro všechny uvažované vzory optimalizační problém, při kterém se minimalizuje celková chyba E , vypočtená ze všech vzorů. V úloze je vektorem neznámých vektor \mathbf{w} , jehož prvky tvoří neznámé váhy, popřípadě i parametry přenosových funkcí a hodnoty prahů. Úkolem je nalézt takovou hodnotu vektoru \mathbf{w} , při které všechny uvedené odchylky nebo předepsané procento odchylek nepřekročí zadanou toleranci. Kritériem může být rovněž součet čtverců odchylek, směrodatná odchylka, průměrná odchylka nebo koeficient determinace apod.

Protože dokonce i malé neuronové sítě mají stovky a tisíce spojnic, mluvíme o minimalizaci skalárního (jednočíselného) pole na vektorovém prostoru se stovkami dimenzí. Pro řešení popsaného problému může být použita řada optimalizačních metod.

Nejužívanější metody, vhodné pro nalezení minima kritériální funkce, jsou gradientní metody. Metoda gradientního poklesu zahrnuje změnu proměnných s malým krokem změnou směrem dolů ve směru lokálního gradientu. Postup má jeden podstatný nedostatek v tom, že lze snadno najít lokální minimum řešení místo globálního maxima, které je cílem řešení. Opustit oblast lokálního minima a pokračovat v dalším řešení však může být obtížné.

V oblasti jednosměrných neuronových sítí se velmi často používá metoda zpětného šíření (backpropagation), kterou je možné přiřadit mezi gradientní metody. Při jejím užití se síť postupně učí pomocí korekce vah v závislosti na odchylce mezi zadanou a vypočtenou hodnotou výstupních signálů ve výstupních neuronech sítě. Korekce signálů (vah) pak probíhá sítí zpětně od výstupní vrstvy neuronů po vrstvu vstupní - podle toho získala svůj název.

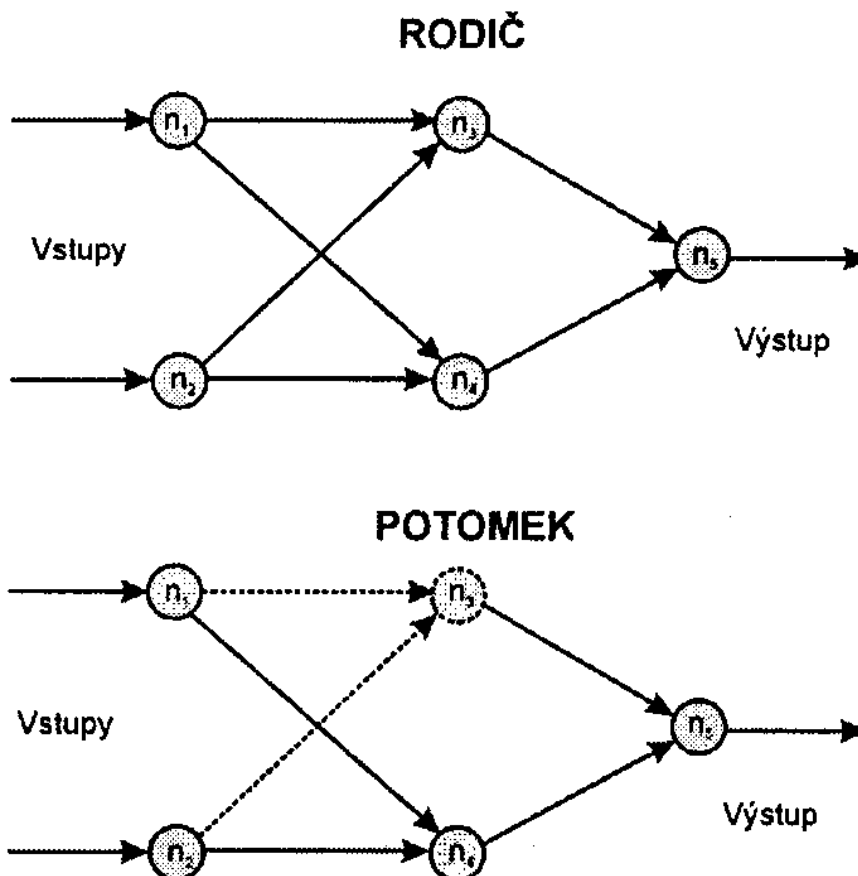
Proces trénování sestává z postupně opakovaných výpočtů výstupů z neuronových sítí při daných vahách pro každý vzor, kdy signály postupují od vstupní do výstupní vrstvy neuronů (forwards) a je vypočtena chyba vzoru E_v . Následně pak probíhá zpětným směrem (backwards) postupný výpočet oprav jednotlivých vah. Je zřejmé, že algoritmus nemůže implementovat celkový (opravdový) gradientní pokles chyby E . Jednotlivé váhy jsou měněny po každé postupné implementaci příslušného vzoru. Praxe ukazuje, že metoda je funkční v naprosté většině testovaných příkladů.

Pokud zavedeme do řešení hodnoty prahů θ jako nulté vstupy do neuronů s hodnotou signálu -1 a s vahou θ , pak se hodnota signálu u každého neuronu v průběhu trénování nemění a zůstává rovna -1 . Opravy změn prahů se pro každý vzor počítají způsobem obdobným jako u změn vah.

Užití genetických algoritmů. Nejnovější verze aplikačních softwarů, jako například BrainMaker Professional, umožňují trénovat neuronové sítě pomocí genetických algoritmů - GTO (Genetic Training Option). Algoritmus, který řídí proces učení, vychází ze dvou známých přístupů - mutace a křížení, které jsou založeny na biologické genetické evoluční teorii. Aplikujeme-li genetické algoritmy na neuronovou síť, je možné nahlížet na spojnice (hrany) mezi neurony i jejich váhy jako na řetězce DNA v živých organismech.

Mutace vyžaduje pouze jednoho rodiče. Během ní je náhodné procento neuronů změněno modifikací vah v hranách, které je spojují. Frekvence změn a velikost jejich změny může být zadána uživatelem (Obr. 13: Schéma mutace neuronové sítě)

Obr. 13: Schéma mutace neuronové sítě

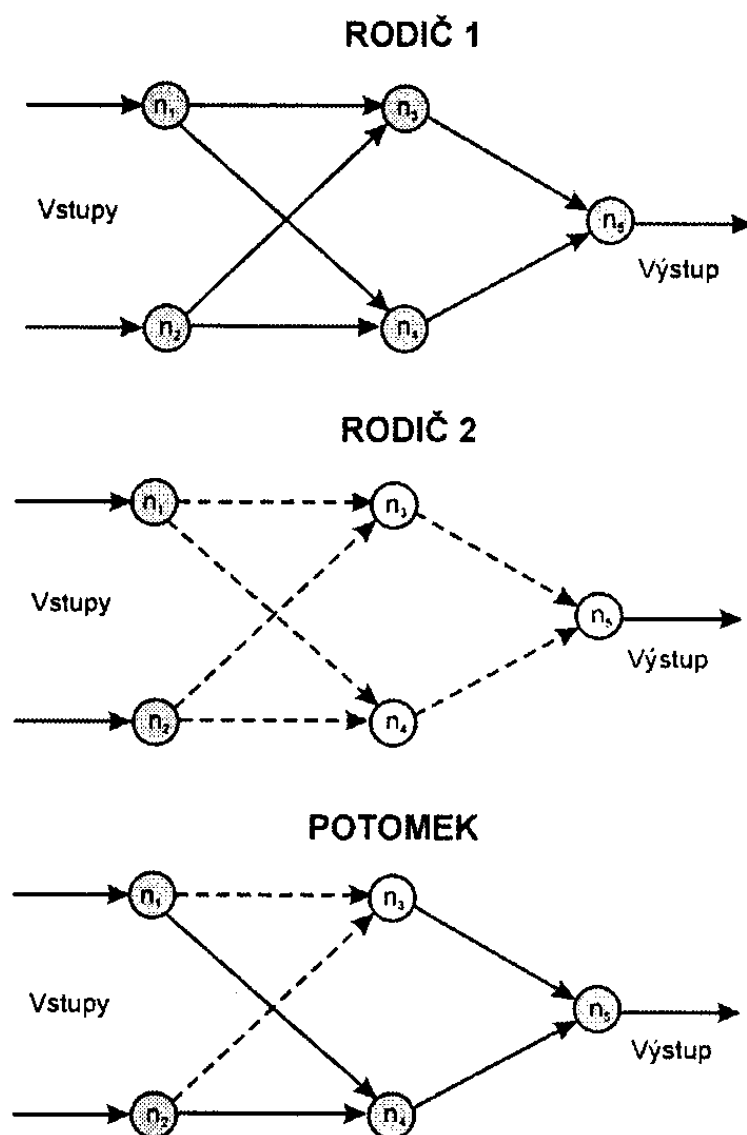


Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

znázorňuje neuronovou síť rodiče a neuronovou síť potomka. V tomto příkladu mutoval skrytý neuron n_3 z rodiče na potomka. Váhy u příslušných hran, které směřují do tohoto neuronu, se změnily.

Křížení vyžaduje dva rodiče. V neuronových sítích je možné je implementovat tak, že ze dvou neuronových sítí - rodičů - vytváříme třetí - potomka.

Obr. 14: Schéma křížení neuronových sítí



Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004

Na obrázku 14: (Schéma křížení neuronových sítí) je znázorněno křížení dvou neuronových sítí. Potomek obdržel skrytý neuron n_3 od druhého rodiče a první skrytý neuron od prvního rodiče (rozumí se váhy u příslušných hran).

Po provedené mutaci nebo křížení je testován potomek - nová neuronová síť. Pokud vykazuje potomek lepší vlastnosti než jeden nebo oba rodiče, nová neuronová síť nahradí rodiče nebo jednoho z rodičů. Přenáší tak informace na budoucí generace neuronových sítí. GTO umožňuje kombinovat mutace a křížení. Protože mutace a křížení jsou aplikovány na váhy hran v neuronové síti, je třeba při spuštění GTO vycházet z natrénované nebo

částečně natrénované neuronové sítě. To znamená mít dostatečný zásobník rodičů pro neuronové sítě.

GTO umožňuje kromě užití genetických algoritmů optimalizovat sestavení a trénování neuronových sítí mřížkovou metodou. Řada parametrů, které se zadávají v softwaru BrainMaker (např. počet neuronů ve skrytých vrstvách a počet skrytých vrstev atd.), je dána nikoliv jednou hodnotou, ale intervalem možných hodnot.

Ke každému intervalu je pak zadán pevný krok změn příslušného parametru. Neuronová síť je pak opakovaně trénována pro všechny možné kombinace hodnot parametrů. Z nich jsou vybrány takové, pro něž je neuronová síť natrénována s nejvyšší přesností.

4.4.4 Topologie neuronových sítí

Jedním ze zásadních problémů při konstrukci neuronové sítě je určení její topologie. Především je nutné zvážit, k jakému účelu bude neuronová síť sloužit, jaké budeme zadávat vstupní veličiny a co bude jejím výstupem. Musíme promyslet, které veličiny mohou mít vliv na výstup neuronové sítě. V této fázi je nutné zapomenout na různé procedury, pravidla nebo vzorce. Je potřeba uvažovat o veličinách a jejich možných vztazích jako takových. Různorodost vstupních dat s vazbou na výstupní veličinu zvyšuje šanci nalézt významnou korelaci (vzájemný vztah) mezi veličinami. Dále je třeba si uvědomit, zda budeme mít k dispozici dostatek vzorů obsahujících veličiny vybrané jako vstupy a výstup neuronové sítě. Je zřejmé, že při určení počtu neuronů ve vstupní a výstupní vrstvě se po provedení těchto úvah nevyskytnou žádné větší problémy. Počet vzorů je dán počtem vstupních a výstupních veličin. Dimenze vstupní a výstupní vrstvy je tedy dána charakterem řešené úlohy. Problémy však nastávají při určení počtu skrytých vrstev neuronů, počtu neuronů v těchto vrstvách a nutném počtu tréninkových vzorů. Problém volby počtu skrytých vrstev a skrytých neuronů je záležitostí každého řešitele. Doporučení pro volbu počtu skrytých vrstev v neuronové síti je problematické.

K použití nejjednodušších třívrstvých sítí se přiklání řada autorů, nicméně téměř stejný počet autorů aplikuje více skrytých vrstev. Přitom není prokázáno, že více skrytých vrstev vede jednoznačně k lepším výsledkům. Praxe ukazuje, že je vhodné započít trénování s jedinou vrstvou skrytých neuronů.

Libovolná funkce může být aproximována již třívrstvou neuronovou sítí s $2m + 1$ neurony ve skryté vrstvě, kde m je počet vstupních neuronů. Pokud v neuronové síti navrhne

více skrytých vrstev, dostáváme se do méně prozkoumané oblasti a musíme postupovat obezřetně. Především podstatně prodloužíme dobu trénování. Pokud navržená síť nejde natrénovat, je vhodné zmenšit počet vrstev a znovu začít s jejím trénováním.

Volba počtu skrytých neuronů je rovněž problémem a pro zodpovězení otázky, týkající se počtu skrytých neuronů, neexistuje žádný univerzální vzorec. Velký počet skrytých neuronů může vést k zapamatování si vzorů. Jestliže však máme malý počet neuronů, neuronová síť se nedá dostatečně natrénovat. Lze uvést několik doporučení k určení postačujícího počtu skrytých neuronů. Jedním je natrénovat několik neuronových sítí s různým počtem skrytých neuronů a vybrat z nich tu, která dává při testování nejlepší výsledky. Dalším doporučením je určit počet neuronů ve skryté vrstvě jako průměrnou hodnotu z počtu vstupních a výstupních neuronů. Jiné doporučení je započít trénování s menším počtem skrytých neuronů a pokud se nedaří síť na požadovanou toleranci natrénovat, postupně přidávat další skryté neurony. Dokud se schopnost učení nezlepší. Je však možné postupovat i opačně. Zpočátku trénovat neuronovou síť s větším počtem skrytých neuronů a následně vyjmout spojnice nebo celé neurony, které poskytují velmi malé výstupní signály. Pak je třeba opakovat trénování neuronové sítě se zmenšeným počtem skrytých neuronů. Uvedená technika se nazývá prostřih. S touto technikou ale musíme zacházet opatrně. Pokud vyjmeme příliš mnoho spojníc (skrytých neuronů), můžeme se vrátit k řešení opačného problému spojeného s malým počtem skrytých neuronů v neuronové síti.

Pokud má neuronová síť problémy s dosažením správných výsledků, může být jednou z příčin malý počet tréninkových vzorů použitých k natrénování. Tento problém je statistického rázu. Když poměr počtu tréninkových vzorů k počtu neuronů klesá, narůstá pravděpodobnost vzniku libovolného vztahu mezi vstupy a výstupy. To se dá vyjádřit ještě jednodušším způsobem. Čím méně tréninkových vzorů v porovnání s počtem neuronů máme k dispozici, tím je větší pravděpodobnost, že síť sice natrénujeme, ale ta nebude naučená správně.

S ohledem na nutný počet tréninkových vzorů doporučuje jedno z pravidel volit počet parametrů modelu (vah neuronové sítě) menší než počet všech vzorů v trénovacím souboru. V opačném případě hrozí přetrénování (overfitting) a ztráta generalizační schopnosti neuronové sítě. To znamená, že síť má příliš mnoho spojů mezi neurony a není schopna dosáhnout zobecnění vztahu mezi vstupy a výstupy. Příliš mnoho skrytých neuronů může tedy způsobit, že si neuronová síť zapamatuje vzory, místo toho aby se podle nich učila. Neuronové síť bude možné velmi dobře trénovat. S jejími testy to však

bude podstatně horší. Ve spojitosti s tímto jevem se užívá termín, že neuronová síť je přetrénovaná. Pro dosažení správných výsledků je vhodné trénovat hubenější neuronovou síť s menším počtem skrytých neuronů, ale pro trénink použít dostatečný počet vzorů vstupních dat, rovnoměrně pokrývajících řešenou oblast. Běžná praxe ukazuje, že počet tréninkových vzorů by měl být přinejmenším roven součinu počtu skrytých neuronů a reciproké hodnoty požadované tolerance. Pokud máme například 10 skrytých neuronů a požadovanou toleranci rovnu 0,1, počet tréninkových vzorů by měl být přinejmenším $100=10(1/0,1)$.

Přidání náhodného šumu k tréninkovým datům může napomoci procesu učení neuronové sítě. Umožní částečně změnit data, kdykoliv jsou předložena k trénování. Přidání šumu je obzvláště užitečné, pokud máme omezený počet vzorů dat. Nejvhodnější velikost šumu činí proces trénování obtížnějším, ale ne nemožným. Přidání šumu ke vstupním datům se osvědčuje, když tréninková data obsahují mnoho nulových hodnot. Neuronová síť se mnohem lépe učí, pokud vstupní vzory obsahují místo nul malé hodnoty čísel. Někdy se osvědčuje po natrénování neuronové sítě přidat šum ke vstupním datům a pokračovat v trénování. Takto dotrénované sítě v praxi často vykazují velmi dobré výsledky. Neuronová síť totiž mohla uváznout v pasti lokálního minima kritériální funkce a rozkmitání vstupních dat jí může pomoci z takovéto pasti vyváznout. Kombinace zašumění vstupních dat a prostřihování skrytých neuronů napomáhá k zobečňování závislostí mezi daty ve vstupních vzorech.

Základní postup pro optimalizaci topologie neuronové sítě, kdy započneme trénování s malou sítí a postupně budeme přidávat další skryté neurony nebo popřípadě vrstvy je možné zautomatizovat dokud chyba aproximace sítě neklesne pod požadovanou hodnotu. Pak je ale nezbytné definovat bod, kdy je nutné přidat další skrytý neuron, protože učení stávající sítě již nepřináší žádný další užitek. Tímto způsobem vznikla metoda dynamické neuronové sítě (Dynamic Node Creation), která svou topologii tvoří během učení. Nejznámější dynamickou sítí je Fahlmanova síť označovaná jako Cascade Correlation Architecture. Automatizovat lze i opačný postup, ve kterém se nejdříve navrhne velká dobře konvergující síť a pak se z ní postupně odstraňují zbytečné neurony, protože předimenzovaná síť má slabé zobečňující schopnosti. Pro odhalení těchto přebytečných neuronů existují různé techniky. Nejjednodušší z nich sleduje výstupy z jednotlivých skrytých neuronů. Jestliže jsou výstupy z některého neuronu neustále vysoké, popřípadě neustále nízké, pak je zřejmé, že tento neuron nereaguje na variabilitu vstupních vzorů a může být odstraněn. V případě, že dva skryté neurony dávají

pro všechny vzory stejné výstupy, lze jeden z nich také bez obav odstranit.

Složitější techniky odstraňování zbytečných neuronů jsou založeny na kvantifikaci efektivity jednotlivých neuronů. Mezi ně je možné přiřadit tzv. skeletonizaci, která byla představena prací Mozera a Smolenského. Užitečnost neuronu je posuzována podle vlivu na neurony v další vrstvě, do které vedou jeho výstupní hrany.

Konstrukce neuronové sítě rovněž vyžaduje určení typu přenosových funkcí a jejich rozsahů, určení koeficientu rychlosti učení a vyhlazovacího faktoru. Rychlost učení určuje velikost oprav neznámých veličin v procesu učení (váhy, prahy, strmosti). Vyhlazovací faktor určuje míru vlivu s níž jsou uvažovány minulé korekce opravovaných veličin a míru vlivu s níž jsou uvažovány korekce nově vypočtené (konjugované gradienty).

Dosud byla popsána základní stavba vrstvené neuronové sítě. V té tvoří neurony vrstvy. Neurony dvou sousedních vrstev jsou propojeny systémem hran každý s každým. Existuje však řada dalších možných architektur vrstvených neuronových sítí, které uvedený základní systém rozšiřují a doplňují dalšími spoji mezi neurony. Příkladem jsou rekurentní sítě.

Rekurentní sítě se snaží zdokonalit proces učení zavedením spojů mezi neurony jednotlivých neuronových vrstev.

Rekurentní neurony vznikly jako pokus obohatit neuronovou síť o časový rozměr. Sítě s rekurentními neurony se hodí pro zpracovávání dat, která tvoří časové řady.

Podle topologie je možné rozlišit řadu různých typů neuronových sítí. Užitečnou může být stručná zmínka o kompetičním modelu s Kohonenovou mřížkou, který může pomoci k redukci rozsáhlých dat obsažených v tréninkové množině. Model umožňuje provádět shlukovou analýzu tréninkové množiny. To znamená určení počtu shluků vstupů tréninkové množiny a jejich rozmístění ve vstupním prostoru. Můžeme ho použít jako reduktor mohutnosti tréninkové matice. Matici nahradíme v tomto případě vektory synaptických vah (které jsme získali v procesu trénování) s rozdělením shodným s rozdělením informací v tréninkové množině. Takto redukovaná tréninková množina tedy bude mít z hlediska charakteru obsažených informací stejné proporce jako původní neredukovaná tréninková množina.

4.4.5 Standardizace dat

Standardizací vstupních dat rozumíme transformaci, která je převede na požadované intervaly. Tyto intervaly mohou být různé a mohou se odlišovat podle toho, zda se jedná

o vstupy nebo výstupy neuronových sítí. Pak mluvíme o standardizaci vstupních nebo výstupních dat. Tato transformace může být jak nelineární, tak lineární. Transformaci je nutné provést ještě před započítím trénování sítě a v řadě případů je podmínkou úspěšného trénování.

Například při použití sigmoidy jako nelineární přenosové funkce, jejíž výstupy leží v intervalu $(0,1)$, je transformace výstupních dat nutností a plyne z definice této funkce. Požadovaná výstupní data je třeba přetransformovat rovněž na interval $(0,1)$. Po natrénování neuronové sítě a provedeném výpočtu pro nová vstupní data jsou pak výstupy sítě inverzní transformací převedeny na interval skutečných hodnot výstupních dat. Vstupní data by teoreticky nemusela být pro sigmoidu standardizována, protože definiční obor sigmoidální přenosové funkce je $(-\infty, +\infty)$. Ve skutečnosti je však standardizace vstupů vhodná. Ukázalo se, že učení neuronové sítě je mnohem rychlejší, když jsou vstupní data symetrická. Proto se transformují nejčastěji do symetrického intervalu kolem nuly. Dále se doporučuje, aby vstupní data byla přetransformována do menších hodnot. Důvodem je malá citlivost sigmoidální funkce při větších absolutních hodnotách vstupů.

V zásadě jsou možné dva způsoby standardizace.

- Jednak je to standardizace po sloupcích matice a jednak standardizace po řádcích matice. Častěji se používá standardizace po sloupcích, kdy standardizujeme každý sloupec zvlášť. Každý vstup do neuronové sítě je tvořen obecně jinou veličinou, která má svůj vlastní fyzikální či jiný význam. Je proto přirozené, že také rozdělení každého vstupu je jiné a má i jiný rozsah hodnot. V běžných případech se každá veličina standardizuje do téhož intervalu. Za předpokladu normálního rozdělení vstupní veličiny je možné každý vstupní údaj příslušného sloupce transformovat na normované normální rozdělení. Standardizace výstupních veličin je závislá na typu přenosové funkce. U standardizace výstupních veličin je nutné, aby maximální a minimální možné hodnoty dané veličiny byly dobře zvoleny. Často se vyplatí dosadit za tyto extrémní hodnoty čísla, která tréninková množina třeba ani neobsahuje, ale jsou přitom pro danou veličinu reálná.
- Jinou možností je standardizovat výstupní veličinu preventivně do intervalu $(0,1;0,9)$. Tato standardizace urychlí trénink a ponechává jistou rezervu pro testování, kdy se mohou objevit větší nebo menší hodnoty údajů než při tréninku. V oblasti extrapolace výstupních dat je třeba postupovat obezřetně. Praxí

je ověřeno, že neuronové sítě se vyznačují velmi dobrou aproximací funkcí uvnitř řešené oblasti. Extrapolace funkcí mimo tréninkovou oblast je jejich slabší stránkou a lze ji provádět jen v omezené míře.

Obecně tedy platí, že při minimalizaci kriteriální (energetické) funkce, dané součtem čtverců odchylek, jsou nejlepší výsledky dosaženy, jestliže vstupní a výstupní veličiny v matici vzorů dat mají normální rozdělení pravděpodobnosti. Často je však rozdělení těchto veličin nesymetrické. Pak je třeba příslušnou transformaci provést ve dvou krocích.

- V prvním se asymetrie odstraní nebo zmenší logaritmováním všech prvků daného souboru. Získaný soubor dat má rozdělení normální nebo téměř normální.
- Ve druhém kroku se provede popsaná transformace prvků tohoto souboru na normované normální rozdělení.

4.5 Další typy neuronových sítí

4.5.1 Vícevrstvá síť perceptronů a metoda backpropagation

Vícevrstvá neuronová síť s backpropagation (algoritmus zpětného šíření chyby) je nejznámější a nejpoužívanější model sítě a využívá se v 80 % aplikací. Síť neuronů má zpravidla n vstupních neuronů, m výstupních neuronů a jednu nebo dvě skryté vrstvy. Neurony ve skrytých a výstupní vrstvě jsou spojitě perceptrony.

Učení této sítě metodou backpropagation spočívá v minimalizaci celkové chyby pro všechny vzory trénovací množiny.

Váhy v této síti upravujeme tak, že od váhy předchozího kroku odečteme určitý díl derivace chyby podle této váhy reprezentovaný koeficientem učení. Přitom postupujeme od horních vrstev ke spodním. Od tohoto způsobu byl odvozen název metoda zpětného šíření chyby.

4.5.2 Význam neuronových sítí s aktivační funkcí sigmoida

Ekonomické nebo výrobní procesy jsou zpravidla složitější, než je možné popsat lineární neuronovou sítí. Vícevrstvá neuronová síť spojitých neuronů dokáže složitější zákonitosti postihnout přesněji než neuronová síť lineární.

Je dokázáno, že perceptronové sítě se dvěma skrytými vrstvami mají univerzální aproximační schopnost.

4.5.3 Asociativní síť

Lineární asociativní síť se používá zejména jako asociativní paměť. Na rozdíl od klasických metod vyhledávání v paměti, kdy klíčem je adresa, u asociativní paměti probíhá vybavení informace na základě její částečné znalosti. Asociativní paměti se dělí na autoasociativní. Zde se jedná o upřesnění nebo doplnění vstupní informace. U heteroasociativní se jedná o vybavení sdružené informace.

U topologie a způsobu výpočtu výstupní hodnoty lineární asociativní sítě chybí jednotkový vstup a odpovídající práh je nulový. Při adaptaci je však podstatný rozdíl: požadovaný výstup odpovídá vstupu.

Způsob adaptace podle Hebbova zákona učení je zajímavý tím, že modeluje podmíněný reflex v živé přírodě tak, že současná aktivita nebo pasivita neuronu odpovídajícího podmínce a neuronu vyvolávajícího reflex posiluje synaptickou váhu od prvního neuronu k druhému a naopak nesouhlasná aktivita ji oslabuje.

4.5.4 Hopfieldova síť

Organizační dynamika Hopfieldovy sítě představuje úplnou topologii cyklické sítě s n neurony, ve které je každý neuron propojen se všemi ostatními. Všechny neurony v síti jsou zároveň vstupní i výstupní.

Adaptivní dynamika se řídí Hebbovým zákonem. Tréninkové vzory jsou postupně předkládány síti, jejíž synaptické váhy se podle nich adaptují. Tuto dynamiku lze interpretovat jako hlasování vzorů o vzájemných vazbách.

Cyklickou síť neuronů vzájemně propojených je tedy možné v ekonomických úlohách použít k modelování vztahů mezi objekty. Například v personalistice k modelování vzájemné spolupráce při tvorbě týmů.

4.5.5 Samoorganizace

Principem modelů, využívajících soutěžní strategie, je princip soutěže výstupních neuronů o to, který z nich bude aktivní. Přitom v každém okamžiku je aktivní pouze jeden neuron. Cílem učícího procesu je vytvoření množiny reprezentantů majících stejné pravděpodobnosti výběru. Rozeznáváme učení bez učitele a učení s učitelem.

Úkolem je aproximovat reálné vstupní vektory pomocí konečného počtu reprezentantů. Nejčastěji se používá algoritmus nazývaný Kohonenovo učení.

Organizační dynamika je tvořena dvouvrstvou sítí s úplným propojením jednotek mezi vrstvami.

Aktivní dynamika je zde založena na principu vítěz bere vše.

Adaptivní dynamika zde spočívá v procházení celé tréninkové množiny a úpravě vah vždy po předložení jednoho vzoru. Nejjednodušší varianta vychází z myšlenky posílit správnou klasifikaci posunutím neuronu ve směru vstupu a odsunutím neuronu při nesprávné klasifikaci od vstupu, a to o poměrnou část vzdálenosti od vstupního vzoru. Předkládáme tedy postupně této síti všechny tréninkové vzory.

Tento uvedený typ sítě se dá použít k rozpoznávání nejen grafických tvarů, ale také dalších jevů, například pravděpodobných příčin poruch podle příznaků, rizik podle symptomů apod., přitom výhodou je, že se dokáže učit z příkladů.

4.6 Oblasti využití neuronových sítí

Jaké problémy lze pomocí neuronových sítí řešit, je možné shrnout do několika bodů:

- Neuronové sítě jsou vynikajícím prostředkem pro rozpoznávání závislostí mezi vstupními a výstupními údaji. Pokud potřebujeme nějakou závislost rozpoznat a oklasifikovat. Neuronová síť daný problém vyřeší vždy rychleji a přesněji než člověk. Neuronová síť dokáže opticky rozpoznat cokoli a určit, co to je, když část dat je neúplných nebo neplatných. Tato vlastnost se s velkým úspěchem využívá v medicíně při určování diagnóz (rozpoznávání rakovinných buněk při analýze provedených snímků), při identifikaci letadel z odražených radarových signálů, ale i trhlin v betonu z odražených zvukových vln apod. Uvedené vlastnosti neuronové sítě lze rovněž využít ve vodním hospodářství při konstrukci povodňových varovných systémů pro ohrožené lokality, kdy pomáhají odhalit

hrozící nebezpečí a zároveň ho kvantifikovat konkrétním stupněm povodňové aktivity.

- Neuronové sítě nevynikají přesností. Máme-li například sečíst 4,01 a 4,02, získáme pravděpodobně hrubou odpověď, že 8,0. Pokud tedy potřebujeme výpočty s vysokou přesností, neuronové sítě nejsou vhodným prostředkem.
- Pokud však bude rychlost výpočtu důležitější než přesnost, neuronové sítě jsou tím pravým prostředkem pro řešení. Svoje uplatnění mohou pro tuto vlastnost nalézt zejména při operativním řízení vodohospodářských objektů a soustav, které převážně probíhá za značných podmínek neurčitosti. Výpočty na natrénovaných sítích probíhají řádově v milisekundách až mikrosekundách. Přitom analýza stavů řízených systémů klasickými optimalizačními nástroji a nastavení regulačních uzávěrů může překročit svým trváním přípustné zpoždění, kdy ještě můžeme systém řídit operativně. Zde je použití neuroregulátoru, popř. fuzzy regulátoru, možným řešením.
- Výhodou neuronové sítě je také to, že při případné změně procesu, který řídíme nebo analyzujeme, stačí doplnit nové tréninkové vzory do tréninkové matice a přetrénovat neuronovou síť. To je podstatně jednodušší než sestavení nového výpočetního vzorce, resp. provedení změn pravidel použitých pro řízení systému a s tím spojeného následného přepisu řídicích programů.

4.6.1 Neuronové sítě a co s nimi

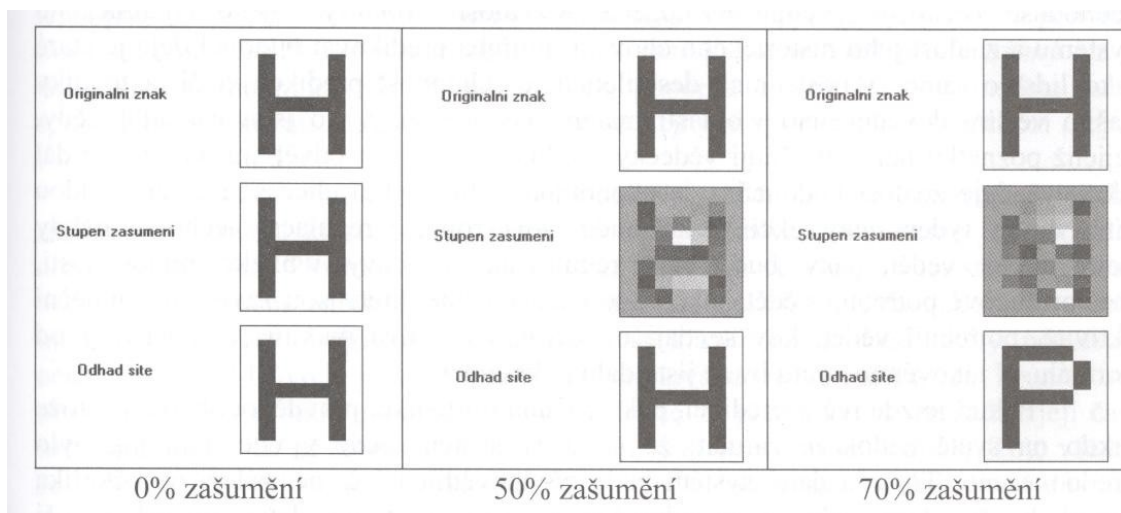
Vše, co bylo doposud řečeno o neuronových sítích, se týkalo jejich podstaty, tj. jak přibližně fungují a z čeho se skládají. V podstatě se dají použít na napodobení jakékoliv lidské činnosti. Jedna z každodenně konaných lidských aktivit, které budou požadovány i po inteligentních strojích, je například rozeznávání. Každý den se mozek potýká s úkolem rozpoznávání objektů v očima získaném obraze a jejich následnému zařazení - klasifikaci. Tyto objekty jsou různého charakteru jako např. písmo, statické objekty (strom, dům) pohybující se objekty (auta, letadla, mraky) a tohle všechno musí mozek velmi rychle zpracovávat a vyhodnocovat. Nebýt schopnosti rozeznávat, tak by lidé neuměli číst a psát, na prvním přechodu by je pravděpodobně něco zajelo atd. Samozřejmě, že samotné rozeznávání nestačí. Spolu s ním musí ještě spolupracovat další části mozku, které se starají o vyhodnocení daného vjemu - objektu, jeho zařazení do příslušné třídy (jedlé,

nejedlé, bezpečné, nebezpečné), ale také i o příslušnou reakci (ucuknutí či natažení ruky, útek, zdvižení potravy k ústům). Jen díky dobře biologicky vyvinutému mozku a jeho následnému dlouhodobému procesu učení se většina biologických tvorů nepotácí místo normální chůze, neumírají hlady vedle potravin apod.

Většinu těchto činností lze díky neuronovým sítím a dalším algoritmům umělé inteligence napodobit alespoň v jejich základní podobě. Toto omezení je dáno jednak tím, že nemáme stále potřebné informace o lidském mozku a jeho jednotlivých funkcích včetně vazeb mezi nimi, ale také tím, že existují i technická omezení.

Neuronové sítě se dají velmi dobře používat na rozeznávání písma. To se dá využít například na předčítání textů pro slepé anebo i v komerčních sektorech pro převod psaného textu do tištěné podoby jako programy, které jsou dnes standardní výbavou scannerů.

Obr. 15: Rozeznávání písma poškozeného šumem pomocí neuronové sítě



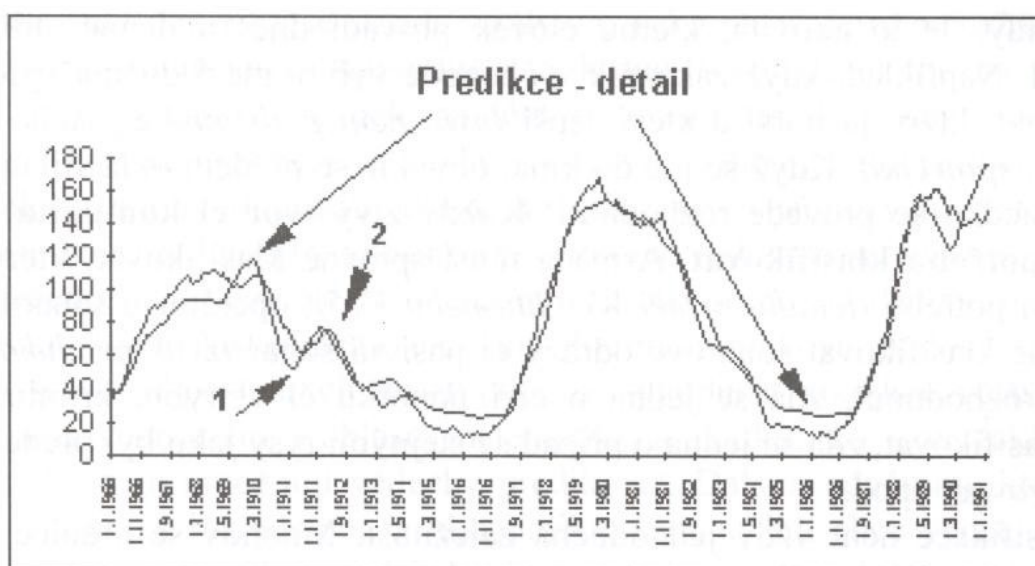
Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003

V rozeznávání písma mají umělé neuronové sítě jednu zajímavou vlastnost. Dokáží dobře rozeznat i velmi nečitelné písmo, které by lidský zrak nedokázal tak dokonale rozpoznat. Neuronové sítě se též dají využít i na rozeznávání řeči, což ve spojení s rozeznáváním písma v blízké budoucnosti zcela změní vzhled počítačů. Dále jsou tendence ovládat počítač pouze lidským hlasem. Tím samozřejmě také dozná změny i operační systém, který je v podstatě pro počítač to, co je pro člověka mícha a systém reflexů. Současné operační systémy budou nahrazeny systémy s rysy inteligence, která bude nezbytná k tomu, aby mohl člověk ovládat počítač hlasem. Ne všichni totiž vysloví své přání stejně a počítač bude muset umět z různých zadaných příkazů na stejné téma odvodit správnou akci.

Další oblastí, kde neuronové sítě již dnes poměrně dobře prosperují, je předpovídání budoucího chování různých systémů jako je například Slunce nebo finanční burza.

S predikcí (předpovídáním) se každý člověk ve svém životě již setkal. Nejlepším příkladem je odhad počasí na další dny. Zejména zkušení horalové dokáží velmi přesně určit, jaké bude počasí za pár hodin či druhý den. Tuto vlastnost jim nabídla historická zkušenost s počasím v dané oblasti, kde se lidský mozek naučil po mnohaletých zkušenostech přiřazovat správné rozhodnutí (počasí zítra) na daný podnět (počasí nyní). Přesně na těchto principech se učí predikovat i neuronové sítě. Trénovací množina, která je za takovýmto účelem zkonstruována, by měla obsahovat ve vstupních vektorech historická data vzhledem k predikovaným datům jak nám ukazuje obrázek (Obr. 16: Předpověď chování Slunce pomocí neuronové sítě).

Obr. 16: Předpověď chování Slunce pomocí neuronové sítě



Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003

Trénovací množina se skládá ze dvojic vektorů, přičemž v každé dvojici je výstupní vektor posunut vůči vstupnímu o tolik dnů, o kolik chceme predikovat. Neuronová síť, která se bude pak na této trénovací množině učit, se díky tomuto posunu naučí přiřazovat budoucí odezvu na momentální podnět.

Problematika předpovědi budoucího chování dynamických systémů je činnost založená na znalosti struktury daného dynamického systému a znalosti jeho historického chování. Potřeba predikovat budoucí děje je stará jako lidstvo samo. V posledních desetiletích

je schopnost predikce větší díky našim větším dovednostem v oblasti matematiky a fyziky. To jsou základní vědy, jejichž poznatky nám umožňují vědecky predikovat. Dalším odvětvím, které čím dál více vyžaduje znalost budoucího, je ekonomika. Mnoho lidí chce vědět, jaké budou zítra či za týden ceny akcií, jaká bude cena ropy. V regulační technice někdy potřebujeme vědět, jaký bude stav regulované soustavy v blízké budoucnosti. Meteorologové zase potřebují vědět, jaké bude počasí a lidé, kteří jsou závislí na sluneční aktivitě, potřebují vědět, kdy se dají očekávat nepříznivá maxima či odchylky od normálu. Jedná se o predikci pravděpodobnou, protože nikdo nedokáže zaručit, že se daný systém bude vyvíjet tak, jak bylo předpovězeno. Jestli bude daný systém předpověditelný či ne, záleží na kritériích:

- zda je predikováno chování systému deterministického či chaotického,
- zda je daný systém popsán dostačujícím počtem rovnic, které popisují jeho strukturu a vazby.

V případě použití neuronových sítí je zde další problém zvaný úplnost dat, což znamená, že z plně deterministického systému je zachycena jeho historie chování, která nemusí obsahovat všechna důležitá data o daném systému.

Z toho tedy vyplývá, že pokud je cílem 100% predikce, musí být o daném systému dostupné všechny informace a v takovém případě pak ani není potřeba neuronové sítě. Ta se uplatňuje u predikování takových systémů, o kterých nejsou dostupné všechny informace, nebo které mohou být rušeny. Pro tuto oblast existují v teorii řízení algoritmy, které umožní i ze silně zašuměných odezev systému vybrat užitečný signál.

Co se týká chaotických systémů, tak zde mnohdy ani neuronové sítě nepomohou. Chaotičnost systému je v podstatě dána divergencí blízkých trajektorií ve stavovém prostoru. U takovýchto systémů vede sebemenší odchylka v počátečních hodnotách k velmi odlišným výsledkům ve smyslu jejich časového vývoje či chování.

Neuronové sítě mají oproti standardním technikám jako matematické modely různých časových řad tu výhodu, že nepotřebují ke své činnosti model a navíc jsou tolerantní k šumu v dané časové řadě. Pojmeme tolerantní se zde rozumí to, že i při zašuměné řadě jsou schopny vyhodnotit odpovídající výsledky v porovnání s klasickými metodami.

V oblasti historického chování se neuronové sítě velmi dobře uplatňují, protože jsou schopny zpracovat mnoho informací najednou. Jsou schopny zpracovat najednou desítky vstupních časových řad a nalézt mezi nimi příslušné vazby a souvislosti, což se pak projeví

na kvalitě předpovědi. To, že dokáží zpracovat takové množství informací najednou, se nejlépe vysvětluje na další činnosti lidského mozku, kterou neuronové sítě napodobují. Tou je klasifikace.

Klasifikace je jednou z oblastí, kde se neuronové sítě velmi dobře uplatňují. Klasifikace znamená v podstatě ohodnocení daného problému a jeho zařazení do příslušné třídy. Je to aktivita, kterou člověk provádí dnes a denně, aniž by si to uvědomoval. Například, když zákazník v obchodě vybírá mezi dvěma výrobky, musí se rozhodnout, který je horší a který lepší (nyní není podstatné z jakého hlediska váha, výkon, spotřeba). Při návštěvě kina se obvykle předem oklasifikuje film a na základě výsledku se provede rozhodnutí. Každý živý tvor či komunita má potřebu klasifikovat. Armáda musí správně klasifikovat, jaký typ letoun je pro její potřebu výhodnější. Operátor u sonaru v ponorce musí správně klasifikovat sonarové odrazy či pasivní sonar a rozhodnout, zda se jedná o cizí ponorku či velrybu. Kriminalista musí správně oklasifikovat, zda se jedná o případ se stejnými rysy jako byl předchozí.

Klasifikace není vždy jednoduchá záležitost. Mnohdy se hranice, na jejichž základě se zařazují klasifikované členy do tříd překrývají. Zde však nachází uplatnění ještě další část umělé inteligence - fuzzy logika. Proč se tedy na klasifikaci a další úkoly používají neuronové sítě? Důvodů je hned několik. Neuronová síť nemá hlad ani žízeň, neunaví se, nevyžaduje plat a může pracovat 24 hodin denně za předpokladu, že žádná její část nebude defektní ať už mluvíme o síti v softwarové či hardwarové podobě. Toto vše by se dalo zahrnout do důvodů ekonomických. Další významnou oblastí jsou důvody technické.

Neuronová síť svá rozhodnutí provádí prakticky ihned i v případě, že vstupních informací popisujících daný problém je dostatečné množství. Co to vlastně znamená dostatečné množství vstupních informací? Například, že na základě vstupních informací binárního charakteru (tzn. 0 nebo 1; černá nebo bílá; ano nebo ne) má být rozhodnuto, kam bude zařazen daný výrobek, pak daný výrobek popisují dvě vstupní proměnné. V tom případě existuje $2^2 = 4$ kombinace, na základě kterých pak může být provedeno ohodnocení daného výrobku. Ale co dělat v případě, když výrobek popisují ne dvě, ale tři (8 kombinací), čtyři (16 kombinací), pět (32 kombinací) a více vstupních proměnných?

Každý z nás jistě najde ve svém životě situaci, kdy se nemohl rozhodnout nebo se rozhodl špatně a přitom vycházel z malého počtu vstupních proměnných. To neuronové sítě nehrozí, pokud je dobře naučena.

Další technickou výhodou neuronové sítě je, že zpracuje všechny předložené podklady. To znamená, že pokud se síť učí například na třiceti či více vstupech popisujících daný objekt na základě sonarového odrazu, pak je síť zpracuje. Co ale udělá člověk? Začne produkovat některé vstupní proměnné a pokud není dostatečně kvalifikovaný a zkušený, pak může vyprodukovat i proměnné, které jsou důležité pro klasifikaci vedoucí ke katastrofě.

Dalo by se namítnout, že neuronová síť je vlastně pilný hlupák, který zpracuje vše, co se mu předloží. Ale není to tak zcela pravda, protože i ona umí pomoci tak zvané neurální citlivostní analýzy (prováděna neuronovou sítí) určit, která informace je vhodná pro zpracování, a která ne. Zatím se zde mluvilo pouze o binárním rozhodování. Pokud by každá z těch třiceti možností mohla nabývat hodnot ne 0 a 1, ale 0, 0,1, 0,2, 0,55 ... tak by se problém klasifikace mírně zkomplikoval.

Klasifikaci lze tedy provádět pomocí binární či spojité funkce pro zařazení do jedné a více tříd.

Tyto zmíněné činnosti na první pohled vypadají odtrženě od reálného života, ale například v jedné plně robotizované továrně, která byla svého času postavena Japonci, se mezi pevnými linkami pohybovaly mobilní roboty převážející materiál. Ty obsahovaly zabudovaný mechanismus, který je zastavil v případě neočekávané překážky. To samozřejmě vyžadovalo nejen pár čidel a bezpečnostní obvody, ale také algoritmy, které by oklasifikovaly danou situaci a rozhodly co má stroj dělat dál. Jestli překážku objet, zatroubit anebo dát na vědomí nadřazené úrovni řízení.

Je jasné, že neuronové sítě jsou nejen velmi všestranný algoritmus, ale také to, že jsou jedním z velmi důležitých algoritmů v rámci umělé inteligence. A to jen díky své schopnosti učit se. Jejich použití při tvorbě inteligentních strojů lze očekávat ve formě klasifikátorů či spíše umělých mozků. Ty pak budou řídit stroje všech druhů v mnoha odvětvích lidské činnosti. Použití neuronových sítí a dalších algoritmů stále více nabývá na významu a lidé se s nimi budou setkávat v běžném životě velmi často, aniž by si to i uvědomovali.

4.6.2 Simulátory neuronových sítí

S umělými neuronovými sítěmi se můžeme setkat v hardwarovém nebo softwarovém provedení:

- V prvním provedení se využívají speciální hardwarové karty do PC, které nahrazují neurony a jejich spojnice pomocí mikroelektronických obvodů a paměťových čipů přímo na kartě. Řešení vyniká značnou rychlostí i v procesu učení, běžnému uživateli je však z mnoha důvodů téměř nedostupné. Využití nachází zejména ve speciálním výzkumu a ve vojenské technice.
- Druhé provedení je založeno na softwarové simulaci neuronových sítí. Sestavené algoritmy je možné provozovat na běžném počítači. Vyžadují však značnou spotřebu strojového času v procesu učení. Při učení rozsáhlých neuronových sítí může i na běžných velmi výkonných PC spotřeba strojového času přesáhnout několik dnů. Protože jsme však schopni sestavit a natrénovat neuronovou síť v předstihu (režim off-line), lze tento nedostatek ve většině případů pominout. Vlastní výpočet natrénovanou sítí je však velice rychlý a pohybuje se obvykle v řádu milisekund a mikrosekund. Softwarových simulátorů byla pro tento účel ve světě vyvinuta celá řada s větší či menší úspěšností.

Z dostupného komerčního software můžeme uvést tyto produkty:

- BrainMaker Professional - Software byl vyvinut společností California Scientific Software z USA. Ta má ve světě uznávané vedoucí postavení v oblasti prostředků vyvinutých pro simulaci neuronových sítí. Síť, které umožňuje simulovat, jsou převážně jednosměrné vícevrstvé. Software umožňuje výběr z řady běžně užívaných přenosových funkcí. Pro trénování se užívá metoda backpropagation. Software sestává ze dvou částí. První část - NetMaker - slouží pro import a přípravu dat a je schopný importovat data z různých databázových a tabulkových procesorů. NetMaker je vybaven speciálními funkcemi pro manipulaci se sloupci, řádky a umožňuje základní aritmetické a statistické funkce a speciální analýzu dat. Druhou část softwaru tvoří vlastní softwarový emulátor neuronových sítí - BrainMaker. V zásadě umožňuje dotvořit neuronovou síť, (určit počet skrytých neuronových vrstev a v nich počet neuronů, podmínky a přesnost trénování apod.), natrénovat síť, provést testování její přesnosti a následně spustit pro vstupní soubor výpočet. Součástí softwaru je možnost použít rekurentních sítí a rekurentních neuronů, které umožňují lepší zpracování dat tvořících časové řady. Samozřejmostí je možnost použít automatické optimalizace topologie sítě, kdy si program sám přidává další skryté neurony, dokud není dosaženo požadované přesnosti transformace. BrainMaker dovoluje vizuálně kontrolovat učení neuronové sítě

a verze Professional obsahuje možnost převzít zdrojový kód naučené sítě do vlastního programu (Runtime Licence). Novinkou od verze 3.1 je možnost aplikace genetických algoritmů Genetic Training Option (GTO) pro trénování a mřížkové optimalizační rutiny pro automatické dotvoření topologie sítí. Speciální verze umožňuje spolupráci s akceleračními kartami CNAPS, které výrazně urychlují trénování rozsáhlých sítí.

- ARTINT - Software byl vyvinut společnostmi Mentar a EGÚ z naší republiky. Je možné jej považovat za první komerční software u nás. Simulátor umožňuje pracovat se čtyřmi modely neuronových sítí.
 - 1. Lineární model V tomto softwaru je vlastně jednovrstvá lineární síť. Vstupní vrstva v něm je současně i výstupní, takže tréninková množina A obsahuje pouze vstupy. Slouží k autokorekci předkládaných vzorů vstupních dat, která mohou být náhodně poškozena.
 - 2. Kompetiční model s Kohonenovou mřížkou provádí shlukovou analýzu. Jeho užití spočívá v možnosti snížit mohutnost tréninkové množiny A.
 - 3. Nelineární model je jednosměrná vícevrstvá nelineární síť. Proces učení probíhá modifikovanou metodou zpětného šíření - backpropagation. Nelineární model je zjednodušenou obdobou sítě užívané v softwaru BrainMaker, lze však zadat maximálně dvě vrstvy skrytých neuronů, přenosovou funkci tvoří pouze sigmoida.
 - 4. Optimalizační model je schopen najít řešení optimalizačních úloh typu problému obchodního cestujícího.
- MATLAB - Neural Networks Toolbox - Matlab je integrované prostředí pro vědeckotechnické výpočty, které obsahuje vlastní programovací jazyk, vestavěné algoritmy, různé analýzy a prezentace dat, grafy, numerické výpočty a simulace. Prostředí je doplněno řadou knihoven (toolboxes), které rozšiřují jeho možnosti do různých oblastí vědy a techniky. Jednou z takovýchto knihoven funkcí, které poskytuje, je i knihovna zaměřená na simulaci neuronové sítě. Knihovna (Neural Networks Toolbox) představuje velmi flexibilní prostředí pro simulaci většiny známých sítí a používá řadu učících metod včetně základního algoritmu backpropagation.

- WinNN - WinNN představuje velmi účinný nástroj pro simulaci vícevrstvé neuronové sítě. Umožňuje volbu z celé řady přenosových funkcí a všechny trénovací parametry mohou být měněny během samotného tréninku. Učení sítě probíhá pomocí algoritmu backpropagation. Uživatelé ocení názorné grafické zpracování dat a výsledků učení sítě. Vedle základních parametrů sítě lze nastavit i hodnotu vstupního šumu.
- Neural Connection. Program klade důraz na ikony nástrojů a jejich užití pro vstup, výstup, modelování a filtrování dat. Neural Connection dává uživateli možnost rychle a přehledně vytvořit na obrazovce požadovanou neuronovou síť. Vytváření aplikací je realizováno pomocí ikon nástrojů pouhým přenesením zvoleného nástroje do pracovního prostoru obrazovky a propojením s jinými ikonami nástrojů. Software obsahuje užitečné regresní nástroje pro analýzu a předpovědi dat a k redukci zbytečných vzorů.
- Neurex - Jde o původní český produkt. Simuluje vícevrstvé neuronové sítě a zároveň expertní systém na bázi neuronové sítě. Program používá pro učení modifikovanou parametrickou metodu backpropagation. Nabízí možnost modifikovat základní tréninkové parametry a vytváří tak prostor pro experimentování. Program je vybaven pro práci s neurčitostí a s neurčitými daty. To mu umožňuje trénovat neuronové sítě jako expertní systém.

4.7 Návrhy možného využití neuronové sítě

4.7.1 Ekonomické informační systémy.

Ve finančních institucích se dnes využívají metody neuronových sítí tam, kde se výzkum v této aplikační oblasti převážně zaměřuje na výhled vývoje některých ekonomických jevů. Například výnosy z cenných papírů na kapitálovém trhu nebo předpovědi vývoje směnárenských valutových kurzů. V obchodní politice se modelují reakce klientů na konkrétní produktovou nabídku. Sloučení neuronové sítě a fuzzy logiky se využívá v systému pro předvídaní úpadku či krachu. V dalších informačních systémech se neuronové sítě využívají k rozpoznávání textů, ručně psaného písma a ověřování podpisů.

V bankovníctví se využívá velké množství počítačových programů asistujících lidem při prediktivních analýzách. Ty jsou však příliš nákladné neboť jsou předem komplexně naprogramované a jakákoliv změna tohoto programu se pak stává časově i finančně nákladnou úlohou.

Neuronové sítě nám však přináší v těchto oblastech nový druh operačního nástroje, který není omezen nějakými přesnými rovnicemi anebo pravidly neboť mohou sami hledat vzájemné vztahy mezi dodanými daty. Vytvořené zákonitosti získané během jejich učení z různých příkladů se pak stávají součástí těchto sítí. Tím se neuronové sítě dokáží nejlépe adaptovat ke konkrétnímu řešení určité problematiky a stávají se tak expertem na tuto problematiku. Využití takovéto vytvořené neuronové sítě pak může být velkým přínosem pro instituci jejíž zejména obchodní výsledky jsou závislé na schopnosti správné predikce událostí. Například vývoj cen místního kapitálového trhu je ovlivněn velkým množstvím externích faktorů cizích kapitálových trhů a domácími i celosvětovými ekonomickými událostmi.

Neuronové sítě můžeme implementovat do jakékoliv aplikace a kombinovat je i s jinými metodami pro potřeby získání lepších výsledků v mnoha různých úlohách. Pokud však neuronová síť nemá dostatečné množství potřebných dat a příkladů, není možné od ní očekávat správnou a uspokojující prediktivní analýzu. Neuronová síť nám též po její aplikaci není schopna podat srozumitelnou interpretaci svého výsledku neboli podat přesné vysvětlení jak dosáhla konečného výsledku. To vše záleží na dodání dostatku kvalitních a ověřených dat a jejím správném učení z předložených příkladů.

V současné době zatím neexistují žádná konkrétní pravidla či koncepty pro řešení určitých druhů predikce. Tudíž je při trénování neuronové sítě použit i subjektivní lidský názor na konkrétní oblast požadovaných faktorů. Člověk sám totiž ani nemůže s určitostí říci, které dodávané informace jsou více důležité než ostatní a zda jejich vývoj nebyl ovlivněn jinými informacemi, které při trénování neuronové sítě nebyly vůbec použity.

Neuronové sítě se však zdají v současné době tou nejlepší modelovací metodou pro predikci událostí neboť sama dokáže nalézt nelineární vztahy mezi daty v systému bez faktoru lidské pomoci. Vylepšením výkonu neuronových sítí se můžeme dostat ke srozumitelnějšímu pochopení složitých dynamických systémů zejména kapitálových finančních trhů.

4.7.2 Vyhodnocení finanční situace podniku

Možnost automatizovaného vyhodnocování finanční situace podniku za pomoci využití výstupů z oblasti umělé inteligence neuronových sítí může vést k výraznému omezení podnikatelských rizik a umožňuje v dlouhodobém horizontu zajistit finanční stabilitu podniku pokud nedisponuje finančním expertem.

Nejvhodnějším způsobem využití se jeví nasazení neuronové sítě na jejímž výstupu je aproximované řešení vypovídající o finančním stavu podniku. Tím lze však řešit pouze jednoznačné případy, které bývají mnohdy časově náročné na jejich vyhodnocení.

Hodnocení finanční situace podniku je převážně typem úlohy klasifikační. Cílem je sestavení systému umožňujícího identifikovat například negativní finanční situaci podniku stejným způsobem jako podnikový finanční analytik. Před vlastním hodnocením neuronovou sítí je potřeba ji naučit na vhodných datech podniku. Podpora rozhodovacího procesu na úrovni podnikových pravidel je pak řešena expertními systémy a fuzzy expertními systémy kde vstupními údaji rozhodovacího problému musí být finanční ukazatele likvidity a zadluženosti - výstupem je pak hodnocení stability a aktivity spolu s rentabilitou - výstupem je hodnocení výnosnosti.

Výstupní kategorie specifikuje finanční expert s ohledem na hodnocený segment trhu a dané časové období tak, aby odpovídaly typickým podnikovým procesům hodnocení. Vzhledem k náročnosti stanovení exaktních pravidel pro vyhodnocení podnikové finanční situace musí být zvolen přístup hodnocení na základě historických dat. Elementárním vstupním vzorem je zde n-tice hodnot finančních ukazatelů daného podniku za dané období. přiřazení odpovídající výstupní kategorie všem vstupním vzorům opět provede finanční expert.

Takto připravená data pak slouží pro naučení neuronové sítě, která je teprve poté schopna klasifikovat nové vzory podobně jako posuzující finanční expert. Učení neuronové sítě bude provedeno obvyklou metodou zpětného šíření chyb (backpropagation) s jejími modifikacemi.

Použijeme tedy vícevrstvou perceptronovou neuronovou síť, kde neurony vstupní vrstvy odpovídají vstupním finančním ukazatelům a výstupní vrstva bude upravena podle finálního počtu výstupních kategorií. Jedna z těchto výstupních kategorií bude představovat atypickou finanční situaci, při které je pak nakonec nutné analytické posouzení člověkem.

5 Aplikace umělé inteligence

Aplikace umělé inteligence s sebou přináší i spoustu zamyšlení nad jejím využitím v běžném životě člověka. Kapitola nám ukáže několik příkladů využití umělé inteligence a zamyšlení nad případnými možnými hrozbami při nesprávném používání této vědní disciplíny.

5.1 Příklady reálných aplikací

Technologie neuronových sítí lze využít téměř v každé situaci, ve které je cílem nalezení neznámé proměnné nebo vlastností na základě známých pozorování. To znamená naměřených hodnot v nejrůznějších formách regresí, klasifikací a časových řad a je-li k dispozici dostatečné množství historických dat. Existují-li též mezi nimi objektivní vztahy nebo množina vztahů. Dále lze neuronové sítě použít pro vyšetřovací analýzu pro případ hledání shluků dat využitím Kohonenovy sítě.

Následující seznam uvádí výběr některých příkladů použití této technologie:

- Optické rozpoznávání znaků, včetně rozpoznávání podpisů - jistá společnost například vyvinula zařízení, které určuje pravost podpisu nejen podle celkového vzhledu písma, ale i rychlosti pohybu psacího náčiní při podpisu.
- Zpracování obrazu - byl například vyvinut systém, který sleduje obrazy z londýnských stanic metra a dokáže rozpoznat, zda je stanice zaplněna, prázdná nebo poloprázdná bez ohledu na světelné podmínky či přítomnost-nepřítomnost vlakové soupravy ve stanici.
- Předpověď finančních časových řad - společnost LBS Capital Management například tvrdí, že se její obchodní výsledky podstatně zlepšily použitím vícevrstvé sítě perceptorů pro předpovědi cen akcií.
- Úvěrová rizika - klasický problém. Na základě dotazníku rozhodnout, zda je uchazeč o úvěr vhodnou osobou z hlediska úvěrového rizika.
- Výběr skupiny zákazníků pro hromadnou korespondenci - identifikace zákazníků, u kterých je nejvyšší pravděpodobnost příznivé reakce na hromadnou korespondenci na základě informací z existující databáze zákazníků.

- Detekce a ohodnocení v medicíně - například detekce epileptických záchvatů, odhad velikosti tumoru prostaty.
- Monitorování stavu strojů - odhadování, kdy může dojít k poruše vlivem vibrací nebo akustických zátěží a následné plánování preventivní údržby.
- Syntéza řeči - slavným příkladem z této oblasti byl známý Nttalk, který se učil vytvářet fonémy na základě psaného textu.
- Předpovědi na základě chaotických časových řad - mnoho výzkumných pracovníků prokázalo schopnost neuronových sítí dosahovat dobrých odhadů na základě chaotických časových řad.
- Řízení procesů - například monitorování strojního zařízení v průmyslových procesech a průběžné nastavování řídicích parametrů.
- Systémy provozování strojů - odhady spotřeby paliv na základě snímaných měření.
- Jazyková analýza - použití neuronové technologie pro identifikaci klíčových frází a slov v domorodých jihoamerických jazycích.

5.2 Aplikace genetických algoritmů

Genetické algoritmy mohou být užity při řešení celé řady problémů, především těch, kde se běžně využívají metody optimálního programování. Jde o vyhledání optimálního řešení problému podle zadané kritériální funkce. Zde mohou genetické algoritmy nahradit jiné standardní optimalizační algoritmy, protože jim hrozí menší riziko, že uváznou v pasti lokálního extrému. Přitom se uplatňuje především výhoda jejich paralelismu, kdy jedinci populace cestují prohledávaným prostorem současně na mnoha různých místech. Výhodou genetických algoritmů je i jejich snadná implementace. Pokud již máme k dispozici algoritmus pro řešení úlohy určitého typu, nebývá obvykle problém s jeho přenesením na obdobnou úlohu.

Nevýhodou genetických algoritmů bývá obvykle větší spotřeba strojového času než u klasických optimalizačních metod. Mohou být pomalejší než jiné standardní algoritmy, například gradientní metody. Tato okolnost však již není problémem vzhledem k výkonnosti současné výpočetní techniky.

Uvedme některé oblasti aplikací:

- nelineární dynamické systémy - predikce, analýzy dat,
- umělé neuronové sítě - topologie, proces učení,
- neuro-fuzzy genetické systémy - topologie, proces učení,
- genetické programování - vývoj programů psaných v jazyce LISP,
- strategické plánování,
- řešení problémů obchodního cestujícího.

5.3 Řešení omezujících podmínek

Dokážeme-li formulovat omezení nějaké optimalizační úlohy ve formě energetické funkce neuronové sítě, pak proces její relaxace povede k nalezení některého z optimálních, či alespoň suboptimálních řešení.

Stanovíme váhy mezi jednotlivými neurony na základě porovnání obecně definované funkce energie Hopfieldovy sítě a energetické funkce vyjadřující naše omezující podmínky.

5.3.1 Problém obchodního cestujícího

Problém obchodního cestujícího (Travelling Salesman Problem – TSP) je klasickou úlohou, kterou lze uvedeným postupem úspěšně řešit. Cílem úlohy je navštívit všechna města oblasti tak, aby žádné z nich nebylo navštíveno dvakrát a přitom, aby délka trasy byla co nejmenší. Nejlepší řešení pro TSP je velmi složité najít, neboť čas potřebný pro jeho nalezení roste exponenciálně s počtem měst.

Omezením je, že každé město může být navštíveno pouze jednou a trasa musí být co nejkratší.

Pokud se podaří sestavit energetickou funkci, která bude tato omezení odrážet, pak její minimalizace povede k řešení optimalizující tato omezení. Poněvadž výsledkem je seznam měst navštívených v určitém pořadí, budeme potřebovat nějakým způsobem tento fakt vyjádřit. Jestliže n budeme chtít navštívit n měst pak každé z nich se bude nacházet v seznamu na některé z n pozic. Pro potřeby řešení úlohy TSP použijeme čtvercovou

matici $n \times n$ neuronů (všech vzájemně propojených), kde města jsou reprezentována řádky a pořadí sloupci matice:

Obr. 17: Tabulka pořadí navštívených měst


| Město/Pořadí | 1 | 2 | 3 | ... | n |
|--------------|-----|-----|-----|-----|-----|
| A | 1 | 0 | 0 | ... | 0 |
| B | 0 | 0 | 1 | ... | 0 |
| C | 0 | 0 | 0 | ... | 1 |
| ... | ... | ... | ... | ... | ... |
| N | 0 | 1 | 0 | ... | 0 |

Zdroj: VONDRÁK Ivo. Umělá inteligence a neuronové sítě. Scripta. Ostrava : Vysoká škola báňská – technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, 1995

Z příkladu vyplývá následující pořadí navštívených měst $A \rightarrow N \rightarrow B \rightarrow \dots \rightarrow C$.

Hopfield s Tankem realizovali experiment úlohy TSP pro deset měst, přičemž 16 případů z 20 konvergovalo ke správnému řešení. Navíc pak 50 % z nich patřilo k nejkratším trasám nalezených úplným řešením úlohy:

Obr. 18: Problém obchodního cestujícího



(Zdroj: VONDRÁK Ivo. Umělá inteligence a neuronové sítě. Scripta. Ostrava : Vysoká škola báňská – technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, 1995)

Varianta C je optimální a varianta B je suboptimální.

5.4 Člověk versus kyborg

Už současná umělá inteligence v lecčem překoná tu lidskou. Za vše hovoří souboj šachového mistra světa, Rusa Vladimira Kramnik, s počítačem. Počítač zvítězil 4:2, když Kramnik ani v jedné partii neztvítězil, dokázal nanejvýš jen remizovat.

Vědci z univerzity v britském Bristolu dokonce předvedli na veřejnosti robota, který dokáže projevovat emoce. Tento stroj dýchá a tluče mu i jeho srdce. Pokud robota obejmě člověk, robotu se jeho dech i tep zpomalí a jeho končetiny jsou v tu chvíli vláčnější. Pokud však robotovi vynadáte, vyvalí na vás své oči a jeho životní pochody se mu zrychlí. Je však samozřejmé, že se v tomto případě nejedná o emoce v pravém slova smyslu, ale jen o naprogramované reakce.

Umělá inteligence se bude neustále zvyšovat, o tom není sporu, vždyť lidstvo vyžaduje, aby vše bylo špičkovější, výkonnější a kdovíco ještě. V určité fázi se pak objeví etický problém - nemohl by si člověk kus umělé inteligence nechat i pro sebe? Proč si za pomoci některých implantátů nezvýšit mozkovou kapacitu? Americký futurolog Raymond Kurzweil jde ještě dál: "Podobné možnosti poskytuje současný rychlý rozvoj nanomateriálů. Jsem přesvědčen, že v budoucnu budeme schopni posílit strukturu našich kostí i svalů a pravděpodobně i zlepšit účinnost krevního zásobení a značně tak zlepšit naši fyzickou výkonnost."

Inteligenci robotů však netřeba přeceňovat. I když ji robot může mít, jsou stále ještě oblasti, které umělá inteligence přinejmenším do roku 2050 zcela jistě nepřekoná. Kreativita nebo umělecké myšlení zůstane vlastní jen člověku. Emoční pochody u člověka jsou totiž natolik složité a komplikované a vědecky častokrát ještě nevysvětlené, že je otázkou, zda se jim vůbec někdy v budoucnosti podaří umělou cestou alespoň přiblížit.

Ovšem inteligenci robotů je nutno brát i vážně. Například jihokorejská vláda vypracovala etickou normu, která by v budoucnu měla bránit zneužívání robotů lidmi a naopak.

Co se však týče vylepšování lidského organismu moderními technologiemi, je zcela na místě obava, zda se nejedná o cestu do pekel, dlážděnou - jak jinak - dobrými úmysly.

V oblasti počítačových aplikací nabývá umělá inteligence rovněž na významu. V době, kdy existovaly osobní počítače coby sporadicky se vyskytující zařízení bez vzájemného propojení, byla problematika umělé inteligence nejen málo rozpracovaná, ale i nevýznamná pro použití na tehdy pomalých a nevtkonných počítačích. S rostoucí

mohutností PC a jejich vzájemného propojování se však situace mění. Dnešní velké centrální počítače různých společností či superpočítače představují ohromující výpočetní výkon, který je řízen množstvím komplikovaných programů tvořících operační systém daného počítače. Tyto tzv. systémové služby se musí starat o správný chod počítačů, musí umět přizpůsobovat chod počítače v závislosti na jeho zatížení od různých uživatelů, musí řídit a obsluhovat spoustu technických periferních zařízení a navíc musí zvládat i připojení a komunikaci s jinými vzdálenými počítači a sítí Internet.

S rostoucí náročností je jasné, že algoritmy s umělou inteligencí budou v takovém prostředí nabývat stále na větším významu. Není totiž možné připravit operační systém, který by počítal s každou eventualitou. Vždy se vyskytne situace, se kterou programátoři nikdy nepočítali. U současných počítačů to zatím šlo řešit pevným programem, nicméně v blízké budoucnosti se na činnosti počítačů budou podílet i algoritmy umělé inteligence. Ty se budou vyskytovat nejen v jádru takovýchto operačních systémů, kde budou například optimalizovat chod daného systému, ale také v kontaktu s uživatelem pomocí např. hlasového vstupu. Budou se podílet i na zpracování různých dat a požadavků od uživatelů, které mohou být, a také určitě budou, různě formulovány. To budou muset umět počítače správně pochopit a splnit.

5.5 Umělá inteligence a viry

Umělá inteligence se rovněž uplatní i v celosvětové síti, kde bude mít funkci a podobu programů, které se budou starat o optimální chod této sítě, které budou umět rozdělit práci na více počítačů v rámci sítě. Je to takzvaná distribuovaná umělá inteligence, dnes již seriózní odvětví umělé inteligence. Kromě těchto a jiných úkolů budou zastávat úlohu ochránce proti softwarové špionáži a počítačovým virům, které určitě budou budovány s prvky umělé inteligence. Názornou ukázkou je antivirový program od firmy Symantec, který obsahuje prvky umělé inteligence, která mu umožňuje rozpoznat i neznámé viry.

Potenciální hrozbou budou tedy zřejmě počítačové viry.

Viry a umělá inteligence? Ty vychází z evolučních algoritmů, které napodobují evoluční proces přímo uprostřed PC. Není vyloučeno, že vzniknou i viry s umělou inteligencí, které budou schopny samostatné orientace v počítačovém prostředí a adaptace na něj. Podle svých životních podmínek v PC. Jako jsou typ OS, počet útoků ze strany antivirových programů, místo v PC. Budou si moci volit svou strategii rozmnožování,

sebezdokonalování, špionáže a také ničení. K naprogramování takových virů nebude již stačit kdejaká kuchařka, která prošla kurzem programování, nicméně zcela jistě budou lidé, kteří to dělat budou. Bohužel. To ovšem způsobí také vznik inteligentních antivirů.

Po celou naši existenci si lidstvo v sobě nese příčinu svých úspěchů, ale i problémů. To se během jeho vývoje projevovalo jak na vzniku různých vynálezů, tak i na jejich zneužití. Tento typicky lidský přístup se nevyhnul ani oblasti, která je tak charakteristická pro druhou polovinu dvacátého století - počítače.

Čím je větší rozšíření počítačů, tím větší úlohy jsou jim svěřovány. Tím se ale bohužel také stávají terčem lidské aktivity, která by se dala ohodnotit od zlomyslné až po kriminální (průniky do počítačových systémů a krádeže dat nebo viry co zlikvidují například obsah datového disku). Lidé, kteří se touto aktivitou zabývají, jsou označováni jako piráti nebo hackeři a pokud jsou vůbec někdy dopadeni, je jim nakonec obvykle nabídnuta spolupráce v dané firmě. To samozřejmě není nejlepší způsob, jak nalézt práci. Obecně se neautorizované průniky do PC označují jako počítačová infiltrace, pod kterou lze zahrnout neautorizované využití počítače různými cestami jako například:

- Přímo z operátorovy konzoly některým z jeho kolegů či náhodných návštěvníků daného pracoviště. Obvykle to bývá ten nejjednodušší způsob, jak se někam takzvaně vlomit.
- Z detašovaného terminálu nebo prostřednictvím modemu. Tato činnost (hacking) je velmi populární mezi mládeží, která ji bohužel bere jako sport. V tomto případě je velmi obtížné daného hackera vystopovat.
- Pomocí počítačové sítě, přenosných datových médií (převážně viry).

Důvody, které k takovéto infiltraci původce vedou, jsou obvykle:

- Peníze.
Jako příklad lze použít případ jednoho programátora, který pracoval v jisté bance a zjistil, že podniky posílají své peníze pár dnů před splatností. Programově zajistil, aby tyto peníze byly převáděny na jeho konto, kde se mu za pár dnů pobytu těchto peněz přičítaly slušné úroky a pak je vracel zpět v den splatnosti. Dalo by se to charakterizovat rčením: "Vlk se nažral a koza zůstala celá". Nutno poznamenat, že se tento programátor stal milionářem dříve, než se ho podařilo odhalit, ale také to, že dnes již všechny státy s tímto způsobem neoprávněného manipulování s cizím majetkem ve svých zákonech počítají.

- Pomsta.
To obvykle dělají lidé, kteří jsou anebo si myslí, že byli nespravedlivě vypovězeni z pracovního procesu. Hezkým příkladem je opět programátor propuštěný z jisté konstrukční firmy, který zajistil, aby se na každý tištěný konstrukční plán nebo výkres vykreslil do rohu malý medvídek.
- Nepřiměřená obrana.
Existují vážné důvody, že některé programátorské firmy vložily do svého software viry coby ochranu před neoprávněným kopírováním.
- Škodolibost.
Bohužel stále existuje mnoho lidí, kteří jentak pro svou zábavu ničí vše, co je okolo nich. Problém vzniká v momentě, kdy se některý z nich naučí programovat.
- Sport.
Spousta mladých lidí se tímto způsobem baví a soutěží i mezi sebou.

O problémech hackerů by se dalo hodně diskutovat. Některé jejich stránky jsou jednoznačně škodlivé a některé zase potenciálně přínosné. Není žádným tajemstvím, že mnozí programátoři se alespoň jednou pokusili sestrojít vlastní virus. Ne proto, že by se chtěli na této činnosti dále podílet, ale spíše jen proto, že je to pro ně výzva. Většina takových programátorů obvykle své dítě-virus po úspěšném zplození zakonzervuje a uschová nebo zničí. Problém je, že když to neudělají a zdrojový text viru se dostane do rukou psychicky méně vyvinutého jedince, tak to obvykle končí katastrofou.

Doposud k vytvoření virů stačilo znát jazyk typu Assembler či C++ a vlastnosti operačního systému. Na základě toho se obvykle sestavil program, kterému se pak říká počítačový virus. To ale v poslední době platí stále méně, protože komplikovanost systémů, ale i programovacích jazyků neustále roste. Vlastní počítačový virus budoucnosti už nebude jen jednoduchá sekvence instrukcí, jejíž smysl musí určitým způsobem zapadat do činnosti systému jako ozubená kolečka. Lze očekávat, že počítačové viry budoucnosti se již budou podobat jednoduchým živým organizmům, které budou brát daný operační systém jako své životní prostředí. Bude se jednat o adaptabilní programy, které budou provádět vlastní rozhodnutí na základě aktuálních podmínek. Z toho plyne, že takový virus již nebude programován jako přesně daná sekvence instrukcí toho, co se má stát, ale jako sekvence instrukcí, které budou definovat obecná pravidla rozhodování.

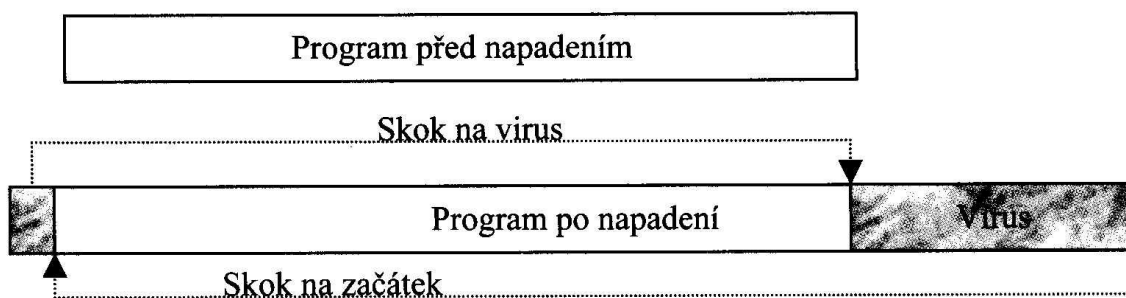
Z toho je vidět, že na rozdíl od klasických virů, u kterých bylo jasné, co budou dělat, zde není jistota, jak se inteligentní virus zachová. Jeho rozhodnutí budou záviset pouze na okolních podmínkách, které na něj momentálně budou působit a na jeho zkušenostech. Bude-li například vytvořen virus na bázi neuronových sítí, fuzzy logiky či expertních systémů a poté rozmnožen kopírováním, pak se pravděpodobně při jeho vypuštění do "světa" stane následující: V okamžiku vypuštění jsou si všechny viry rovny, co se týká zkušeností. Různé viry přijdou do různých počítačů, operačních systémů či počítačových sítí. To znamená také, že se dostanou do působení různých okolních podmínek jako je například, intenzita antivirových kontrol, velikost paměti, disku, úspěšnost při virové činnosti, boj o teritorium apod. Zde je na místě se zmínit, že boj o teritorium není jen slovní hříčkou. Současné i minulé počítačové viry se totiž podobaly lavině, co se množení týče. To znamená například, že nebraly ohled na to, kolik jich je v jednom počítači. To samozřejmě vedlo k tomu, že se takový nakažený počítač dříve nebo později totálně zhroutil z důvodů totální virové nákazy a poškození. Toto chování klasických virů je analogické situaci, v níž se do uzavřeného prostoru vpustí skupina živočichů, která nemá žádné zábrany a tudíž vše vyplní a zkonsumuje vše, bez ohledu na budoucnost. Takový druh musí dříve či později nutně vymřít.

Inteligentní virus, pokud bude opravdu inteligentní, bude mít schopnost nejen provést onu cílovou akci (destrukci, nakažení a tak podobně), ale bude také vědět, že se nemůže množit donekonečna, protože by se přemnožil a tudíž by již neměl co nakazit. Také by tímto na sebe upozornil a to by znamenalo jeho likvidaci. Rovněž bude muset hájit teritorium mimo jiné i z bezpečnostních důvodů. Není totiž velmi bezpečné, aby v jednom počítači bylo např. 10, 20, 500 či více druhů virů. To by opět vedlo k odhalení a následné likvidaci. Jinými slovy, inteligentní viry by se měli chovat spíše jako inteligentní bytosti žijící na omezeném území než jako bezduché počítačové sekvence, což původní viry jsou. A právě v tom leží potenciální možnost, že jejich rozhodnutí budou jedinečná a neopakovatelná. Každý virus bude mít jinou historii svého života, jiné zkušenosti a bude tudíž i jinak rozhodovat.

V tom se ale také skrývá veliké nebezpečí. Budou to totiž programy, jejichž chování bude stěží předpověditelné a to tím více, čím více budou inteligentní a čím déle budou žít. Vzhledem k tomu, že se budou chovat jako inteligentní entity, pak nelze vyloučit, že se najde nějaký programátor, který je vytvoří tak, aby se množily na principu evolučních algoritmů. To by pak znamenalo, že v PC bude probíhat virová evoluce, během které

budou vytvářeny nové a dokonalejší viry, které budou zaujímat místo svých takzvaných rodičů. Existují definice, které tvrdí, že virus musí mít destrukční účinek, což však nemusí být nutně pravda. Tyto definice jsou pak zavádějící, protože virus může mít i špionážní charakter. Je to program, který proniká do systému bez svolení uživatele či vlastníka a vytváří své kopie. Jeho princip je znázorněn na obrázku:

Obr. 19: Princip nakažení - nedestruktivní množení viru



Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003

Obrana proti klasickým počítačovým virům je dnes již na výborné úrovni. Má však z principu jednu nevýhodu. Vždy je o krok pozadu za novými viry. Tvůrci antivirových programů totiž nikdy nemohou vědět, jaké viry vzniknou. V začátcích vývoje antivirových programů se obvykle viry hledaly podle charakteristických řetězců - binárních sekvencí, které se nalézali jen v daném viru. Později přibýly lepší metody, jak se bránit proti virům. A to hlídáním choulostivých aktivit v počítači (jako například kopírování, zápis na disk, a další aktivity). V současné době se antivirové programy dodávají s algoritmy, tedy s rysy umělé inteligence, které by měli zabezpečit, aby se do počítače nedostaly pokud možno ani neznámé viry. Obranu obecně lze dělit na aktivní a pasivní.

- Aktivní obrana je v podstatě jakákoliv přímá akce proti virům. Je to použití antivirů, debuggerů (programů pro ladění a sledování programů přímo v paměti PC) atd. Některé viry jsou tak udělány, že se samy odstraní, jakmile zjistí, že jsou sledovány.
- Pasivní obrana v podstatě znamená, že daný počítač je totálně odříznut od okolního světa. S příchodem skutečných virů s umělou inteligencí bude efektivní obrana PC velký problém. Zvláště, když se vezme v úvahu fakt, že mnoho reálných zařízení je spojeno do počítačových sítí. Nelze tedy vyloučit i takové katastrofické scénáře způsobené viry, jako například výpadek životně důležitých přístrojů v nemocnicích, radarů v letectví, zásobování města energií apod. I když to vypadá jako hudba

z fantastické budoucnosti, je to reálné. Zejména ve vyspělých zemích, které jsou dost computerizovány. Kromě bezhlavého šíření půjde viry s umělou inteligencí také použít jako špionážní prostředek.

Zvláštní kapitolou jsou programy, které neslouží k destrukci jako klasické viry, ale ke špionáži, ať už soukromé, průmyslové či jiné. Tyto programy nemají obvykle klasický virový charakter ve smyslu rozmnožení se dle možností, ale naopak je jejich činnost přímo cílená. Tím cílem je obvykle donést ke svému tvůrci požadovanou informaci. Cesty k získání takových informací mohou být různé. Slušně vytvořený takzvaný špionážní program se pak obvykle potichu vypaří a nezanechá za sebou žádnou stopu.

Se vzrůstající propojeností počítačů a složitostí systémů bude také narůstat i problém jejich ochrany. Klasické metody této ochrany proti počítačové špionáži jako je hlídání podezřelých aktivit na PC nebo monitorování využití přerušení či zamykání PC, už nejsou efektivní. Ať už se nám to líbí nebo ne, faktem je, že průmyslová špionáž bude stále nabývat na významu, protože zdrojů surovin ubývá a to, za co se dnes nejvíce platí, jsou informace.

Význam špionáže poroste také z důvodů nárůstu významu informací a informačních technologií. Někdo kdysi řekl, že se vede skrytá válka, válka o informace a jak se stále více okolo nás ukazuje to pravda je. Bylo by tedy velmi krátkozraké tvrdit, že umělá inteligence by se neměla dále vyvíjet, když jsou takové perspektivy. To co bude, nezávisí pouze na principech a matematických postupech, které představují umělou inteligenci, ale především na nás lidech. My lidé jsme ten problém. Mnohdy se dobrá věc nejprve využije na ničení a teprve poté na užitečnou činnost. Počítačové viry či atomová energie jsou toho dost velkým důkazem.

Závěr

Fakt, že umělá inteligence nezůstane jen na úrovni počítačů, ale přesune se i na pole biologické, je již více než jasný. Za původního otce biopočítačů lze považovat Dr. Leonarda Adlemana (matematik, biolog a kryptoanalytik) z Univerzity of Southern California, který jako první přišel s nápadem využít DNA jako počítače.

Tak, jak konvenční počítače pracují v binární soustavě a používají její čísla 1 a 0, která jsou reprezentována v podstatě určitými napětími, tak DNA znázorňuje informace chemickými jednotkami DNA. Kalkulace s obyčejným počítačem se provádí obvykle pomocí programů, který dává pokyny nižším elektronickým jednotkám, což v konečném důsledku vede k toku různých proudů elektronů v daném počítači. Kalkulace pomocí DNA znamenají syntézu konkrétních sekvencí, které pak na sebe působí. Například logický příkaz AND je u DNA reprezentován oddělením vláken DNA a OR jejich sloučením. Při těchto, ale i jiných operacích, má takovéto DNA-PC spotřebu energie asi miliardkrát úspornější než klasické PC a k uložení informace jim stačí jedna trilióntina místa v porovnání s PC. Nejvýznamnější rys DNA-PC je však to, že je masivně paralelní, což znamená, že s miliardami molekul DNA je možné provést najednou více operací, než kolik by bylo možné provést se všemi PC na celém světě. Jako příklad lze uvést DNA-PC, které by obsahovalo 1020 molekul a mohlo by v malé zkumavce provádět všechny operace současně. Konvenční PC by nemohlo mít více než několik set či tisíc nezávislých procesorů.

Jaká bude tedy budoucnost, záleží hlavně na nás. Na tom, jakou cestu zvolíme a jakých zásad se budeme držet. Můžeme umělou inteligenci využívat v lékařství jako špičkové chirurgy, jako dělníky v těžkých provozech či průzkumníky na cizích planetách. Nebo také jako ničitelé světů. V dějinách lidstva byly všechny dobré vynálezy vždy prve zneužity a teprve poté využity. Lidé si musí uvědomit, že to špatné není v našich objevech a jejich aplikacích, ale v naší samotné podstatě. V tom co jsme a čím jsme v evoluci byli. Lidé nejsou nic jiného než masožraví predátoři, kteří po tisíce roků žili loveckým stylem. Spolu s životním stylem se vytvářel systém pudů a reakcí, které nás doprovází s mírnými změnami dodnes. To vše ovlivňuje naše chování a jednání. Zřejmě proto se většinou téměř každý potenciálně vojensky využitelný objev také vojensky využije. Problém využívání

vědeckých objevů včetně aplikací umělé inteligence bude stejným etickým problémem stejně asi jako klonování živých bytostí.

Aplikacemi se zde nerozumí dnešní v podstatě bezduché a primitivní neuronové sítě apod., ale systémy, které budou mít blízko k inteligentní bytosti. Pro takové stroje budou muset lidé vytvořit nejen etická pravidla a zákony, ale budou se také muset změnit zákony celé lidské společnosti. Jestliže má být námi vytvořen nový inteligentní druh, pak se k němu bude muset přistupovat jako k rovnocennému partneru a ne jako k otroku. Konkrétně tohle by dnešní společnosti dělalo velké problémy. Vždyť ještě dnes jsme se ještě nevypořádali s rasismem, který je v podstatě způsoben jen bezvýznamnými kosmetickými rozdíly mezi rasami homo sapiens. Jsme v rámci tohoto problému opravdu sapiens? Co teprve skutečně nelidský druh? Je to prakticky totéž jako setkání s mimozemskou civilizací. V obou případech budou muset jít stranou všechny xenofóbní reakce a přístupy. Pokud ne, pak to zřejmě skončí katastrofou.

V blízké budoucnosti budeme moci zřejmě vytvářet jak inteligentní entity jaké jsou stroje a software, určené k ničení, tak i k užítku.

Možná se zdá být podivné odvolávat se ve vizích a úvahách na seriály z vědecko-fantastické literatury, nicméně opak je pravdou. Ohlédneme-li se do minulosti, zjistíme, že nejednou byl pokrok vědy inspirován právě díky fantazii v románech. Stačí se podívat na díla Julese Vernea, který ve svých románech popsal mnoho strojů, které vznikly až po mnoha letech. Byly to například ponorky, letadla těžší vzduchu, vrtulníky a lety na Měsíc. A co víc, do těchto románů se také promítá většinou pozitivní přístup a etické řešení problémů. A to je něco co dnes ještě lidem schází.

Jaká bude tedy budoucnost? Těžko říci. Jediným faktem je, že je to jen na nás lidech, jak si svou budoucnost utvoříme.

Seznam použité literatury a zdrojů

1. BĚLOHLÁVEK, Alexander; ŠTĚDRONĚ, Bohumír. *Budoucnost již začala*. Praha : Sdělovací technika, 2003. ISBN 80-86645-06-1.
2. BÍLA, Jiří. *Umělá inteligence a neuronové sítě v aplikacích*. Praha : Vydavatelství ČVUT, 1995. ISBN 80-01-01275-1.
3. JANDA, Martin. *Kdy se smaže rozdíl mezi lidmi a roboty?* 21. století, číslo 1/2009. Praha : Česká unigrafie, 2008. ISSN 1214-1097.
4. MAŘÍK, Vladimír; ŠTĚPÁNKOVÁ Olga; LAŽANSKÝ, Jiří a kol. *Umělá inteligence (I)*. Praha : Academia, 1993. ISBN 80-200-0496-3.
5. NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK, Jiří a kolektiv. *Využití metod umělé inteligence ve vodním hospodářství*. Praha : Academia, 2004. ISBN 80-200-0229-4
6. VONDRÁK, Ivo. *Umělá inteligence a neuronové sítě*. Ostrava : Vysoká škola báňská – technická univerzita Ostrava, 1995. ISBN 80-7078-949-2.
7. ZELINKA, Ivan. *Umělá inteligence - hrozba nebo naděje?* Praha : BEN - technická literatura, 2003. ISBN 80-7300-068-7.

Internetové zdroje

1. *Neural Networks*. [online]. 2009. Dostupný z: <<http://www.statsoft.com/textbook/stneunet.html>>
2. *Příštích 25 let IT techniky*. [online]. 2009. [cit. 2009-01-16]. Dostupný z: <<http://www.veda.cz/article.do?articleId=23126>>
3. *STATISTICA Automatizované neuronové sítě*. [online]. 2009. [cit. 2009-01-23]. Dostupný z: <http://www.statsoft.cz/page/index2.php?neuron_popis>
4. Šindelář, Jan. Pomůže nám superpočítač odhalit tajemství mozku? [online]. 2005. [cit. 2009-01-20]. Dostupný z: <<http://www.zive.cz/Clanky/Pomuze-nam-superpocitac-odhalit-tajemstvi-mozku/sc-3-a-126381/default.aspx>>
5. Teda, Jaroslav. *Intelligentní ekonomické systémy [IV]*. [online]. 2009. [cit. 2009-02-20]. Dostupný z: <<http://programujte.com/tisk.php?cl=2006040402-inteligentni-ekonomicke-systemy-iv>>

6. *Umělá inteligence není jen planým zvoláním*. Dostupný dne 15.1.2009
z: <<http://www.dsl.cz/clanky-dsl/clanek-706/umela-inteligence-neni-jen-planym-zvolanim>>
7. ZOROASTER. *Stručné teze o umělé inteligenci*. [online].2007. [cit. 2008-11-28].
Dostupný z: <<http://ww.pismak.cz/index.php?data=read&id=266803>>

Seznam obrázků

Obr. 1: Tabulka srovnání počítač versus lidský mozek

Zdroj: Presentace, Umělé neuronové sítě z pohledu rozpoznávání, Václav Hlaváč
Centrum strojového vnímání, Katedra kybernetiky FEL ČVUT. Dostupná z:
<http://cmp.felk.cvut.cz/~hlavac/TeachPresCz/31Rozp/72UmeleNN.pp> – dostupná dne 15. ledna 2009.

Obr. 2: Biologický neuron pod mikroskopem

Zdroj: <http://www.dsl.cz/clanky-dsl/clanek-706/umela-intelligence-neni-jen-planym-zvolanim>.
Dostupný dne 15.1.2009.

Obr. 3: Model biologického neuronu

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 4: Model umělého neuronu

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 5: Umělá neuronová síť

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 6: Neuron n_j vyjmutý ze skryté vrstvy

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 7: Sigmoida

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 8: Skoková přenosová funkce

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 9: Lineární prahová přenosová funkce

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 10: Gaussova přenosová funkce

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 11: Nelineární hranice mezi třídami - ideální případ (žádný z členů tříd A, B a C neleží v prostoru druhé třídy)

Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003.

Obr. 12: Schéma tréninkové matice

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 13: Schéma mutace neuronové sítě

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 14: Schéma křížení neuronových sítí

Zdroj: NACHÁZEL Karel, STARÝ Miloš, ZEZULÁK Jiří a kolektiv. Využití metod umělé inteligence ve vodním hospodářství. Praha : Vydavatelství Academia. Praha : 2004.

Obr. 15: Rozeznávání písma poškozeného šumem pomocí neuronové sítě

Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003.

Obr. 16. Předpověď chování Slunce pomocí neuronové sítě

Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003.

Obr. 17: Tabulka pořadí navštívených měst

Zdroj: VONDRÁK Ivo. Umělá inteligence a neuronové sítě. Scripta. Ostrava : Vysoká škola báňská – technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, 1995.

Obr. 18: Problém obchodního cestujícího

Zdroj: VONDRÁK Ivo. Umělá inteligence a neuronové sítě. Scripta. Ostrava : Vysoká škola báňská – technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, 1995.

Obr. 19: Princip nakažení - nedestruktivní množení viru

Zdroj: ZELINKA Ivan. Umělá inteligence - hrozba nebo naděje? BEN - technická literatura. Praha : 2003.