

## 3. Neurónové siete a umelá inteligencia\*

### 3.1 Symbolický verzus subsymbolický prístup k spracovaniu informácií

Podobne ako v umelej inteligencii, tak aj pri neurónových sieťach vzišla historická inšpirácia zo snahy vytvoriť umelý systém schopný vykonávať komplexné, snád' aj "inteligentné" výpočty podobné rutinným operáciám v ľudskom mozgu. Medzi umelou inteligenciou a neurónovými sieťami je teda správne prepojenie v mysli neprofesionálov, no u ľudí zaoberajúcich sa neurónovými sieťami alebo "klasickými systémami umelej inteligencie" je namiesto prepojenia niekedy aj priepasť. Zásadný problém je v tom, že v začiatkoch umelej inteligencie bolo vnútorné presvedčenie (aj keď iba v podvedomí väčšiny programátorov), že človek je predsa len inteligentnejší ako počítač, a počítač môže prekonať človeka, iba ak sa mu presne povie ako na to. Týmto pohľadom je ťažko otriasť, lebo napriek všetkému úsiliu zatiaľ neexistujú programy (ani neurónové siete!) schopné inteligentne pracovať na viacerých problémoch súčasne a učiť sa nie v umelom prostredí, ale v reálnom svete. Na druhej strane majú biologické neurónové siete o niekoľko rádov viac neurónov. No aj tak je otáznym predpoklad, že stačí vytvoriť dostatočne veľký počítač, zaviesť neurónovú sieť, a počítač nadobudne atribúty ľudskej inteligencie.

Tieto, ako aj každé iné tvrdenie spojené s umelou inteligenciou budú najskôr kontroverzné, pretože umelá ako aj prirodzená inteligencia nie je presne definovaným pojmom. Jej základné atribúty by mali zahŕňať schopnosť rozpoznávať vzory, nejaké prvky správania sa metódou pokusu a omylu, a schopnosť učiť sa. Z jedného pohľadu sa ľudia snažia vyvinúť programy riadiace stroje, ktoré by vykonávali to, čo normálne človek nazýva inteligentným správaním sa. Iní išli ešte ďalej, prečo rovno nevymyslieť program, ktorý by sa sám ďalej vyvíjal, aby sa už človek nemusel zaoberať ani tým programovaním. Z druhého pohľadu sa snažia psychológovia, humanisti a neurofyziológovia zistiť, čo je to vlastne tá inteligencia. K tomuto cieľu je najlepšou cestou vytvoriť si umelú inteligenciu a zistiť, či sa "správa" rovnako ako "prirodzená", alebo čo jej chýba, a aké princípy sa zle použili, a na čo sa pozabudlo.

Programy spojené s počiatočným rozvojom umelej inteligencie boli do detailov vymyslené človekom - programátorom, a náhoda v ďalšom vývoji alebo upresňovaní programu nehrala takmer žiadnu úlohu. Človek začal tým, že si predstavil, ako by problém riešil on, a keď sa mu to nedarilo, rozdrobil si problém na časti, ktoré už jednotlivo zvládol. Postup potom naprogramoval do počítača. Automaticky sa predpokladalo, že človek potom dokáže vysledovať, čo vlastne počítač robí, a rozhodnúť, či nejaké dané rozhodnutie počítača bolo správne. Toto presvedčenie sa samozrejme s rastúcou komplikovanosťou programov oslabovalo, no principiálne presvedčenie v podvedomí pretrvávalo. Programy

---

\* "All things are artificial, for nature is the art of God." Sir Thomas Browne (Všetko je umelo vytvorené, pretože príroda je Boží výtvor.)

boli komplikované z hľadiska množstva námahy vynaloženej programátorom na riešenie konkrétneho typu problému. Výsledný program sa síce správal inteligentne, no bola to inteligencia explicitne vložená programátorom, a program bol schopný riešiť iba veľmi obmedzený typ problémov pri presne definovaných podmienkach.

Postupne sa začala preformulovávať aj samotná definícia toho, čo sa považuje za umelú inteligenciu. V počiatkoch to bol každý program, ktorý sa správal tak, že si laik myslel, že na riešenie takéhoto problému je potrebná inteligencia. Typickým príkladom môžu byť šachové programy, ktoré sú síce na veľmajsterskej úrovni, no ich správanie sa je do detailov určené človekom, a keď urobia chybu, tím analytikov je schopný túto chybu napraviť analýzou rozhodovania programu a pridaním nejakého pravidla alebo zmenou nejakej váhy. Takéto programy sa zo začiatku považovali za umelú inteligenciu, no v súčasnej dobe sa vzhľadom k svojej špecializácii na jeden typ problému už väčšinou za umelú inteligenciu nepovažujú.

Ďalším medzníkom v tvorbe inteligentných programov bola teda tvorba takých systémov, ktoré by boli úspešne schopné riešiť väčšiu triedu problémov. Príkladom sú expertné systémy, ktoré sú tvorené "prázdny" balíkom programov, v ktorých je zabudovaný logický postup, ako zaobchádzať s pravidlami, no vlastné zadefinovanie konkrétnych pravidiel pre určitý problém je už úlohou užívateľa expertného systému. Expertný systém je teda schopný nielen odpovedať na otázku, no aj dodať užívateľovi prístupnou formou podrobné vysvetlenie, ako sa k odpovedi na nejakú otázku prišlo. Pokiaľ je odpoveď zlá, užívateľ by mal byť schopný "ručne" pozmeniť pravidlá tak, aby nabadúce dali správnu odpoveď. Vo svojej špecializovanej oblasti môžu pravidlá fungovať perfektne, no akonáhle túto oblasť rozšírime, nájdeme výnimky. Tieto systémy sú ale neobratné pri zahrnutí heuristik alebo výnimiek z pravidiel a neurčitosti zadanej informácie.

Problémom je to, že užívateľ by sa nemal lopotiť s ručným konfigurovaním pravidiel, ale mal by to robiť počítač. Čím viac práce sa ale necháva na počítač, tým je vo všeobecnosti menšia šanca, že by človek bol schopný prekontrolovať postup nejakého rozhodnutia tak, aby rozumel, ako k nemu počítač "dospel". Tento posun od zrozumiteľnosti k nezrozumiteľnosti však niekedy nemusí byť pozvoľný, ako je tomu napríklad v rozdiel medzi sčítaním desiatich čísel a desiatich tisíc čísel, kedy sa hranica možnosti kontroly počítača človekom stáva nezreteľnou. Skokový posun je v rozdiel medzi exaktným "logickým" prístupom a len ťažko formálne popísateľným "analogovým" prístupom, alebo inak povedané, medzi prístupom založenom na

symbolickej logike a medzi subsymbolickým prístupom, kde je výsledok spoluvytváraný príspevkami mnohých hodnôt parametrov neurónovej siete spracovávajúcej informáciu. Prírodovedecká a počítačová komunita bola privyknutá veriť, že všetko, vrátane inteligencie, musí mať jednoduché, kompaktné vyjadrenie v reči symbolov a matematických zákonov. To však nevyzerá byť pravdou pri subsymbolickom prístupe.

Začala sa vynárať nová myšlienka, a to tá, že počítače už fakticky môžu byť lepšie nielen pri riešení čisto numerických problémov alebo pri zret'azení logických úsudkov, no aj v komplikovaných systémoch pri iných problémoch, ktoré doteraz boli doménou človeka. Tu už nestačí narábať so symbolmi alebo celými číslami — reálne čísla a obrazová či akustická informácia je nevyhnutná. Takéto problémy sa typicky skladajú z veľkého množstva drobných interakcií vytvárajúcich celkový pojem či obraz [63]. Vyžaduje sa flexibilita, použitie "podobnosti", kompromisov, analógií, metafor a výnimiek. Človek pritom už nie je schopný preniknúť do činnosti počítača a rozhodnúť, či sa v danom prípade počítač rozhodol správne, alebo nie, a tu problém spočíva nie v množstve dát, ale v ich reprezentácii. Súčasne však takáto architektúra riešenia problému najskôr lepšie zodpovedá procesom v mozgu ako súbor dopredu daných pravidiel a znalostí spojených s rigidným systémom, ktorý určuje, ako s týmito znalosťami zaobchádzať. Zatiaľ ale zďaleka nejde o to, žeby počítač sám od seba vymyslel niečo, čo mu človek dopredu nepovedal. Architektúra v súčasnosti používaných neurónových sietí je zvyčajne presne definovaná človekom pre ten ktorý typ problému. No hranice toho, čo je treba počítaču explicitne povedať, a toho, čo je schopný sám si vypočítať sa pomaly posúvajú. Dá sa iba dúfať, že schopnosť počítačových systémov vytvárať, modifikovať a vysvetľovať hypotézy bude postupne narastať.

Taktiež prístup k tvorbe logického a analógového systému je iný. Pri neurónových sieťach človek ťažko dopredu povie: synaptická váha má byť taká a taká. Je potrebné vytvoriť automatizovanú procedúru učenia sa. Takéto učiace procedúry ale zaberajú veľa strojového času počítača. Aj vzhľadom k tomu, že v dobe začiatkov umelej inteligencie bol čas počítača drahší vo vzťahu k času programátora, ako je tomu dnes, neurónové siete sa vo vývoji oneskorili za heuristickým programovaním založeným na logike. No s rozvojom počítačov tento nepomer začína prevažovať na druhú stranu.

Príklad rozdielu medzi klasickým symbolickým a subsymbolickým spracovaním informácie je prístup k rozpoznávaniu vzorov (angl. *pattern recognition*). Jeden spôsob je jednoducho skladovať všetky možné prípady a každý nový porovnávať so všetkými predchádzajúcimi. Klasické symbolické spracovanie sa pokúša skomprimovať prípady do malého súboru pravidiel, a potom skladované prípady vyhodiť. Neurónové siete sú niekde medzi tým, vo všeobecnosti u nich nemožno jednoznačne rozdeliť naučené pravidlá od informácií vo vzoroch, oboje sú totiž kódované synaptickými váhami a aktiváciami neurónov.

Neurónové siete sú trocha extrémnym príkladom posunu v tvorbe systémov. Namiesto symbolických informácií prenášajú cez komunikačné kanály a spracovávajú vo svojich základných jednotkách numerické informácie. Sú schopné aspoň čiastočne sa učiť, no zatiaľ žiaden systém nevykazuje normálne myslenie, ani na úrovni dieťaťa. Sily spojení medzi neurónmi, tzv. synaptické váhy, predstavujú distribuovanú formu uchovanej informácie. Pokiaľ je neurónová sieť správne natrénovaná, dáva vynikajúce výsledky, no ani dosť podrobnou analýzou nie je človek väčšinou schopný pochopiť, na základe čoho neurónová sieť k výsledku dospela. To považuje komunita klasickej umelej inteligencie za najväčší nedostatok, pretože jej systémy sú schopné zjednodušiť vysvetlenie natoľko, že človek je ho ešte stále schopný sledovať. Neurónové siete fungujú ako čierna skrinka, do ktorej vložíme vstup, vypadne z nej výsledok, no nedostaneme vysvetlenie, prečo akurát takýto výsledok. Jedným zo súčasných trendov výskumu v oblasti neurónových sietí je snaha túto čiernu skrinku "vykradnúť", extrahovať z nej pravidlá a znalosť zakódovanú v numerických koeficientoch siete, a to tak, aby sa tieto pravidlá dali použiť napríklad v expertnom systéme. Pri vyššom počte parametrov je pre expertný systém veľmi ťažké vyextrahovať z distribuovaných príspevkov znalosť, pretože zo štruktúry, ktorá nie je rozčlenená (alebo má veľmi veľa častí, ktoré navyše nie sú rozlíšené), je ťažké vyberať oddelené "kusy" informácií.

Nedá sa povedať, ktorý prístup je lepší, či ten založený na prísnej logike, alebo subsymbolický prístup neurónových sietí. Obidva prístupy majú svoje uplatnenie. Keď vieme, že sa niečo správa na základe zákonov a princípov, ktoré poznáme, a máme dostatok informácií ako určiť súčasný stav, môžeme predpovedať budúce správanie sa a budúce stavy, a vzhľadom na to, že prírodné zákony sú väčšinou priehľadné, dá sa presne sledovať logický reťazec od vstupov do výstupov, od príčin k následkom. Vtedy nemá veľký zmysel používať neurónové siete. Tie vzhľadom k svojej "voľne" definovanej architektúre (v porovnaní so symbolickými systémami) niekedy dosť ťažko hľadajú veľmi zložité vzťahy, ktoré keď už dopredu poznáme, ľahko ich zabudujeme do klasického symbolického systému. Keď sú vstupné informácie neisté alebo nepoznáme presne zákonitosti systému, ktorého správanie sa snažíme predpovedať, vtedy sú neurónové siete vhodnou voľbou. Príkladom takých problémov môže byť klastrovanie, klasifikácia, či rozpoznávanie vzorov. No pritom ani neurónové siete nie sú vo všeobecnosti schopné rozpoznať jednotlivé objekty figurujúce na zložitej scéne (zatiaľ čo v prípade, že je objekt "odseparovaný", ho rozpoznajú). Podobne je tomu pri analýze zložených štruktúr, ako sa nachádzajú vo frázach prirodzeného jazyka.

Minsky [46, 47] navrhuje hybridný systém, ktorý by bol schopný využiť prednosti oboch typov systémov, a to tak, že by sa rozhodovalo podľa typu problému, ktorý z prístupov skôr použiť. No aj keď sa pokusy o tvorbu takýchto hybridných systémov objavujú [29], zatiaľ to vždy ešte funguje najlepšie, keď rozhodne človek, ktorým zo špecializovaných prístupov sa bude ten ktorý problém riešiť.

## 3.2 Oblasti použitia neurónových sietí

Čo sa dá realizovať pomocou neurónových sietí, a čo sa nedá?

V princípe môžu neurónové siete spočítať akúkoľvek spočítateľnú funkciu, t.j. môžu robiť čokoľvek, čo dokáže číslicový počítač. V praxi sa neurónové siete najviac používajú na klasifikáciu a funkčnú aproximáciu alebo mapovanie funkcií pri použití množstva tréningových dát, kde systémy s jasne stanovenými pravidlami (ako sú expertné systémy) zlyhávajú. Neurónové siete sú pritom tolerantné k neurčitostiam v tréningových dátach.

Na druhej strane neurónové siete ťažko zvládajú manipuláciu so symbolmi.

Neurónové siete by mali byť teoreticky lepšie a rýchlejšie v porovnaní s väčšinou výpočtov založených na symbolickej logike, pretože sa dajú ľahko rozparalelniť tak, aby bol každý neurón "implementovaný" na jednom procesore. Vzhľadom k tomu, že výpočty jednotlivých prvkov sú na sebe do značnej miery nezávislé, bude celý výpočet o mnoho rýchlejší. Na druhej strane, zatiaľ neexistuje veľa počítačov vybavených veľkým počtom procesorov, takže väčšina aplikácií beží na jednoprocessorových strojoch. Výhoda rozparalelnenia je v súčasnosti teda skôr teoretická.

Medzi najčastejšie oblasti použitia neurónových sietí patria:

- Počítačová informatika — skúmanie vlastností nesymbolického spracovania informácie [12, 41, 42, 62];
- Inžinierstvo — automatické riadenie, spracovanie signálov a veľa ďalších aplikácií [9, 10, 26];  
Jednou z prvých komerčných aplikácií bolo (a ešte stále je) tlmenie šumu na telefónnych linkách [61, ADALINE v kap. 2.5]. V oblasti kybernetiky je známa aplikácia v riadení výroby [14, 45], alebo napríklad na cúvanie dlhých trajlerov [50]. Ďalším príkladom je automatické rozpoznávanie ručne písaných poštových smerovacích čísel [37] alebo analýza otláčkov prstov v kriminalistike.
- Finančníctvo — modelovanie vývoja trhu, rozhodovanie pri prideľovaní pôžičiek alebo pri určovaní veľkosti splátok alebo aj overovanie podpisov na šekoch [4, 51, 57];
- Fyzika — modelovanie javov v štatistickej mechanike [11];
- Chémia — predikcia fyzikálno-chemických vlastností zlúčenín [64], riadenie chemickej výroby [9], analýza dát z analytických meracích prístrojov [15], analýza spektroskopických dát — klasifikácia zlúčenín, predikcia spektier, molekulárne modelovanie — predikcia sekundárnej a terciárnej štruktúry proteínov [64];
- Jadrové inžinierstvo [34], jadrová fyzika a spektroskopia [21].
- Biológia — interpretácia nukleových sekvencií [20];
- Medicína — návrh diagnózy na základe príznakov a výsledkov laboratórnych vyšetrení (napr. diagnóza elektrokardiogramov, diagnóza testov na rakovinu, diagnóza sonogramov a röntgenových snímok apod.) [2, 3];
- Štatistika — flexibilná lineárna a nelineárna regresia a klasifikácia [44];
- Neurofyziológia — skúmanie senzorických systémov, motoriky, rozpoznávanie a produkcia reči [59], modelovanie neurofyziológie mozgu [6, 24, 36, 43, 58];
- Neuropsychológia — modelovanie psychických funkcií [17, 31, 32, 53, 54];
- Ďalšie oblasti ako poľnohospodárstvo (ohodnocovanie a triedenie ovocia), meteorológia (predpoveď počasia), astronómia (klasifikácia galaxií), atď.

### 3.3 Možné smery vývoja

Medzi nielen možné, ale isté (aj keď neveľmi vzrušujúce) smery rozvoja neurónových sietí patrí väčšia **spolupráca so štatistikou**. Najtypickejší nedostatok, ktorý vytykajú štatistici mnohým aplikáciám neurónových sietí, je príliš malý počet tréningových príkladov v pomere k veľkému počtu optimalizovaných parametrov. Čo sa týka súvislosti so štatistikou, väčšina typov neurónových sietí je schopná učiť sa a generalizovať zo zašumených dát, v čom sú podobné štatistike. Napríklad perceptróny sú príbuzné niektorým lineárnym modelom. Neurónové siete s dopredným šírením a jednou skrytou vrstvou sú blízke regresii projekcií. Veľa výsledkov zo štatistickej teórie nelineárnych modelov môže byť priamo aplikovaných na tieto siete. Zatiaľ čo na učenie menších neurónových sietí je výhodnejšia napr. Newtonova metóda [27] alebo metóda konjugovaných gradientov [5], pri väčšom množstve synaptických váh je rozumnejšie použiť Levenberg-Marquardovu metódu [38, 39]. Pravdepodobnostné neurónové siete (PNN) vykonávajú jadrovú (angl. *kernel*) diskriminačnú analýzu. Neurónové siete realizujúce vektorovú kvantizáciu dávajú podobné výsledky ako "k-spriemernená" (angl. *k-means*) klastrová analýza. A neurónové siete učiace sa pomocou hebbovského pravidla sú schopné nájsť smery s maximálnou varianciou v dátach, čo odpovedá analýze hlavných komponent (angl. *principal component analysis*). Kohonenove samoorganizujúce sa mapy sú vzdialene príbuzné "k-spriemer-nenej" alebo skôr "l-spriemernenej" klasterovej analýze.

Problém, ktorý často zabraňuje efektívnej spolupráci so štatistikmi, je v terminológii, ktorú si ľudia zaoberajúci sa profesionálne neurónovými sieťami vyvinuli vlastnú, nezávisle na terminológii v štatistike. Okrem toho ľudia pracujúci s neurónovými sieťami často ignorujú predpoklady týkajúce sa distribúcie dát, s ktorými majú čo do činenia. Pritom sa dajú štatistické výsledky úspešne použiť pri neurónových sieťach. Napríklad, keď niektoré tréningové vzorky sú viac zašumené, je výhodnejšie použiť váhovanú metódu najmenších štvorcov namiesto klasickej chybovej funkcie [7, 44, 52].

Aj keď nasledujúce dve pravidlá vyzerajú v súvislosti so štatistikou triviálne, treba ich zdôrazniť, aby nedošlo k zbytočným chybám a objavovaniu už objaveného. Pri klasifikácii do viac ako dvoch nezoradených kategórií je treba dať pozor, aby každá kategória mala vlastný výstupný neurón. Napríklad keď sú výstupom tri farby (ktoré pre náš účel nemá zmysel zoradovať podľa frekvencie v spektre), potom by výsledok siete mal vyzeráť takto

Červená	1	0	0
Zelená	0	1	0
Modrá	0	0	1

namiesto

Červená	0
Zelená	0,5
Modrá	1

Keď nám vychádza suma väčšia ako jedna a my chceme sumu výsledkov rovnú jednej, aby jednotlivé výstupy boli interpretovateľné ako "pravdepodobnosti", potrebujeme, aby

suma pravdepodobností bola rovná jednej. To sa bežne dosahuje použitím tzv. "softmax" aktivačnej funkcie: teda keď výstup bez použitia aktivačnej funkcie by bol  $q_i$  pre  $i$ -tu kategóriu z celkového počtu  $c$  kategórií, potom pravdepodobnosť priradenia výsledku  $i$ -tej kategórii bude  $p_i$

$$p_i = \frac{\exp(q_i)}{\sum_{j=1}^c \exp(q_j)} \quad (3.1)$$

Keď máme iba dve kategórie, táto funkcia sa redukuje na jednoduchú logistickú funkciu. Podobne je niekedy výhodné normovať alebo štandardizovať vstupné dáta.

V prípade, že potrebujeme klasifikačnú metódu, ktorá nám zistí prípady, v ktorých je klasifikácia neistá, je vhodné použiť PNN (angl. *Probabilistic Neural Network*), čo je termín zavedený Donaldom Spechtom pre jadrovú diskriminačnú analýzu (angl. *kernel discriminant analysis*). Môže sa o nej uvažovať ako o normalizovanej RBF (angl. *Radial Basis Function*) sieti [25, 40, 41, 44, 56].

Podobne funguje aj Spechtom navrhnutá GRNN (angl. *General Regression Neural Network*) [40, 48, 55, 60], čo je alternatívny termín pre Nadaraya-Watsonovu jadrovú regresiu (angl. *kernel regression*). Môže sa považovať za normalizovanú RBF sieť s jednotlivými vnútornými uzlami špecializovanými pre jeden tréningový prípad.

V prípade "preučenia" (angl. *overfitting*) alebo nedostatočnej konvergencie (angl. *underfitting*, bližšie vysvetlenie v podkap. 5.5.3) je niekoľko metód, ako sa týmto extrémom vyhnúť. Výber modelu (angl. *model selection*) sa týka počtu váh, tréningovanie "s šumom" (angl. *jittering*) [7], zoslabovanie váh (angl. *weight decay*) [7, 52], včasné zastavenie učenia (angl. *early stopping*) [49] a bayesovský odhad (angl. *Bayesian estimation*) sa týkajú veľkostí váh [7, 22].

Ďalším typickým problémom je odhad chyby pri zovšeobecnení. Najčastejšie používané je rozdelenie dát na tréningovú a testovaciu množinu (viď podkap. 5.5.1). Často používanou možnosťou je *cross-validation* [7, 22], teda vynechanie podmnožiny vzorov (zvyčajne jedného) zo všetkých prístupných tréningových dát. Takto môžeme použiť na tréningové všetky dáta, ktoré máme, no tréningovanie musí prebiehať pre všetky možnosti vynechania vzoru (vzorov), teda veľa krát. Ešte lepší odhad za cenu ešte väčšej spotreby počítačového času poskytuje tzv. *boot-strapping* [16, 28, 40].


**"Fuzzy" logika**, zavedená v šesťdesiatych rokoch Lotfi A. Zadehom z Berkeley, je zásadným rozšírením klasickej dvojhodnotovej logiky a teórie množín. Používa neostro definované lingvistické premenné (ako "veľký", "horúci", "vysoký") a kontinuálny interval pravdivostných hodnôt [0,1] namiesto striktné binárnych rozhodnutí alebo priradení ("true" alebo "false"). Táto logika sa používa v prípadoch, keď je obtiažne vytvoriť exaktný model skúmaného systému, ale máme k dispozícii aspoň nejaký hrubý model. Takéto systémy boli doteraz riadené ľuďmi — expertmi. Typický fuzzy systém, ktorý má experta nahradiť, pozostáva z databázy pravidiel, funkcie priradenia (angl. *membership function*) a inferenčnej procedúry.

Neurónové siete možno využiť pri konštrukcii priradovacích funkcií fuzzy množín a pre riešenie fuzzy relačných rovníc. Keď je už zostavený fuzzy riadiaci prvok alebo fuzzy expertný systém, klasickej dopredná viacvrstvová neurónová sieť so spätným šírením ho môže nahradiť, využívajúc pritom paralelné spracovanie informácií.

Okrem nahradenia už hotových fuzzy systémov klasickými neurónovými sieťami sú tu pokusy vytvoriť alternatívne neurónové siete, kde vstupy, výstupy a váhy sú fuzzy čísla. Navyše váhované vstupy do každého neurónu nie sú sumované, ale je použitá iná, fuzzy operácia [1, 8, 30, 33, 35].

V súčasnej dobe je veľká časť pozornosti zameraná na to, akým spôsobom by mohli byť symbolický a subsymbolický prístup spojené do jedného celku, ktorý by zahŕňal najlepšie rysy oboch prístupov. Základnými témami sú napríklad obraz a symbol — spojité výpočty v reálnych číslach a vynáranie sa diskretných hodnôt, extrakcia a vkladanie symbolickej informácie do neurónových sietí a tvorba klasických systémov symbolického spracovania informácie na subsymbolických základoch. Jedným z najpopulárnejších príkladov takýchto snáh je prepojenie neurónovej siete s expertným systémom do **hybridného systému**.

Neurónové siete v súčasnosti trpia rovnakým nedostatkom ako systémy založené na symbolickej logike. Totiž tým, že sú naučené iba na jeden typ problémov. Aby dokázali riešiť väčšie spektrum problémov, je predsa len nevyhnutné nejaké vnútorné rozdelenie pôvodne homogénnej siete. Je niekoľko prístupov, ako spojiť subsymbolický a symbolický prístup [29]. Môžu sa prekrývať, čiastočne prekrývať, bežať paralelne alebo za sebou, alebo byť vnorené jeden do druhého. Zatiaľ najčastejšie spojenie je najskôr sériové, kedy výstupy z jedného systému (najčastejšie neurónovej siete) tvoria vstupy do druhého systému (založeného na symbolickej logike). "Znalostne" založené neurónové siete sú postavené na teórii alebo apriórnych znalostiach o tej ktorej oblasti. Neurónové siete sa starajú o také problémy ako je šum alebo neistá informácia, s ktorou klasické znalostné systémy nie sú schopné zaobchádzať.





Inou možnosťou je hybridný systém založený na symbolickej logike, ktorá sa postupne dopĺňa adaptáciou.

Ďalším prístupom je **extrakcia znalostí z neurónovej siete** do expertného systému. To je základ pre vysvetlenie správania sa neurónovej siete a objavovanie znalostí zakrytých šumom a neistou informáciou. Tieto algoritmy sú však exponenciálne náročné vzhľadom k počtu neurónov vo vrstvách [18, 19]. Táto myšlienka môže byť tiež použitá pre zabránenie preučenia siete. Z klasických neurónových sietí s dopredným šírením sa extrahujú pravidlá typu IF-THEN-ELSE a pravidlá formálnych gramatík je možné extrahovať z rekurentných neurónových sietí [13, 23].

## Literatúra

- [1] H. Adeli and S.-L. Hung. *Machine Learning. Neural Networks, Genetic Algorithms, and Fuzzy Systems*. J. Wiley, NY, 1995.
- [2] J.A. Anderson. Cognitive capabilities of a parallel system. In: E. Bienenstock, F. Fogelman-Souli, and G. Weisbuch, editors. *Disordered Systems and Biological Organization*. NATO ASI Series, F20, Springer-Verlag, Berlin, 1986.
- [3] časopis *Artificial Intelligence in Medicine*, Elsevier Press.
- [4] M.E. Azoff. *Neural Network Time Series Forecasting of Financial Markets*. J. Wiley, NY, 1994.
- [5] D.P. Bertsekas. *Nonlinear Programming*. Athena Scientific, Belmont, MA, 1995.
- [6] E. Bienenstock. A model of neocortex. *Network: Computation in Neural Systems*, 6: 179-224, 1995.
- [7] C.M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press, Oxford, 1995.
- [8] M. Brown and Ch. Harris. *Neurofuzzy Adaptive Modelling and Control*. Prentice Hall, NY, 1994.
- [9] A.B. Bulsari, editor. *Neural Networks for Chemical Engineers*. Elsevier Press, Amsterdam, 1995.
- [10] A.B. Bulsari and S. Kallio, editors. *Engineering Applications of Artificial Neural Networks*. Proceedings of the International Conference on Engineering Applications of Neural Networks (EANN '95). Finnish Artificial Intelligence Society, 1995.
- [11] C. Campbell, D. Sherington, and K.Y. Wong. Statistical mechanics and neural networks. In: I. Aleksander, editor. *Neural Computing Architectures*. The MIT Press, Cambridge, MA, 1989, pp. 239-257.
- [12] A. Cichocki and R. Unbehauen. *Neural Networks for Optimization and Signal Processing*. J. Wiley, NY, 1993
- [13] A. Cleremans, D.S. Ervan-Schreiber, and J. McClelland. Finite state automata and simple recurrent neural networks. *Neural Computation* 1(3): 372, 1989.
- [14] I.F. Croall and J.P. Mason, editors. *Industrial Applications of Neural Networks*. Springer-Verlag, Vol. 1 (Project 2092 ANNIE), 1992.
- [15] D. Dong and T.J. McAvoy. Sensor data analysis using autoassociative neural nets. *Proceedings of the 1994 World Congress on Neural Networks*, (5-9 June 1994). San Diego, CA, Vol. 1, 1994, pp. 161-166.

- [16] B. Efron and R.J. Tibshirani. *An Introduction to the Bootstrap*. Chapman & Hall, London, 1993.
- [17] M. Enquist and A. Arak. Symmetry, beauty and evolution. *Nature*, 372: 169-172, 1994.
- [18] L.M. Fu. Rule learning by searching on adapted nets. In: *Proceedings of AAAI-91* (Anaheim, CA), 1991, pp. 590-595.
- [19] L.M. Fu. Rule generation from neural networks. *IEEE Transactions on System, Man and Cybernetics*, 28 (8): 1114-1124, 1994.
- [20] L.M. Fu. *Neural Networks in Computer Intelligence*. McGraw-Hill, Singapore, 1994, chapter 16.
- [21] S. Gazula, J.W. Clark, and H. Bohr. Learning and prediction of nuclear stability by neural networks. *Nuclear Physics A*, Vol. A540, pp. 1-26, 1992.
- [22] A. Gelman, J.B. Carlin, H.S. Stern, and D.B. Rubin. *Bayesian Data Analysis*. Chapman & Hall, London, 1995.
- [23] C.L. Giles, C.B. Miller, D. Chen, G.Z. Sun, H.H. Chen, and Y.C. Lee. Extracting and learning an unknown grammar with recurrent neural networks. In: *Advances in Neural Information Processing Systems 4*. Morgan Kaufmann, San Mateo, CA, 1992.
- [24] M.A. Gluck and D.E. Rumelhart, editors. *Neuroscience and Connectionist Theory*. Lawrence Erlbaum Associates, Hillsdale, 1990.
- [25] D.J. Hand. *Kernel Discriminant Analysis*. Research Studies Press, 1982.
- [26] S. Haykin. *Neural Networks, A Comprehensive Foundation*. Macmillan, Englewood Cliffs, NJ, 1994.
- [27] J. Hertz, A. Krogh, and R. Palmer. *Introduction to the Theory of Neural Computation*. Addison-Wesley, Redwood City, CA, 1991.
- [28] J.S.U. Hjorth. *Computer Intensive Statistical Methods Validation, Model Selection, and Bootstrap*. Chapman & Hall, London, 1994.
- [29] V. Honavar and L. Uhr, editors. *Artificial Intelligence and Neural Networks: Steps Toward Principled Integration*. Academic Press, Boston, 1994.
- [30] C.H. Chen, editor. *Fuzzy Logic and Neural Network Handbook*. McGraw-Hill, NY, 1996.
- [31] R.A. Johnstone. Female preferences for symmetrical male as a by-product of selection for mate recognition. *Nature*, 372: 172-175, 1994.
- [32] M. Juhola, A. Vauhkonen, and M. Laine. Simulation of aphasic naming errors in Finish language with neural networks. *Neural Networks*, 8: 1-9, 1995.
- [33] S. V. Kartalopoulos. *Understanding Neural Networks and Fuzzy Logic: Concepts and Applications*. IEEE Press, CA, 1996.
- [34] W.J. Kim, S.H. Chang, and B.H. Lee. Application of neural networks to signal prediction in nuclear power plant. *IEEE Transactions on Nuclear Science*, Vol. 40, pp. 1337-1341, 1993.
- [35] B. Kosko. *Neural Networks and Fuzzy Systems*. Prentice-Hall, Englewood Cliffs, NJ, 1992.
- [36] A. Koster, A. Zippelius, and R. Kree. Modelling of the Bonhoeffer-effect during LTP learning. *Network: Computation in Neural Systems*, 5: 259-275, 1994.
- [37] Y. LeCun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, and L.D. Jackel. Handwritten digit recognition with a backpropagation network. In: D.S.

- Touretsky, editor. *Advances in Neural Information Processing Systems 2*. Morgan Kaufman, San Mateo, CA, pp. 396-404, 598-605.
- [38] K. Levenberg. A method for the solution of certain problems in least squares. *Quart. Appl. Math.*, 2: 164-168, 1944.
- [39] D. Marquardt. An algorithm for least-squares estimation of nonlinear parameters. *SIAM J. Appl. Math.*, 11: 431-441, 1963.
- [40] T. Masters. *Advanced Algorithms for Neural Networks: A C++ Sourcebook*. J. Wiley, NY, 1995.
- [41] T. Masters. *Practical Neural Network Recipes in C++*. Academic Press, Boston, 1994.
- [42] T. Masters. *Signal and Image Processing with Neural Networks: A C++ Sourcebook*. J. Wiley, NY, 1994.
- [43] M. Matsugu and A.L. Yuille. Spatiotemporal information storage in a content addressable memory using realistic neurons. *Neural Networks*, 7: 419-439, 1994.
- [44] D. Michie, D.J. Spiegelhalter, and C.C. Taylor. *Machine Learning, Neural and Statistical Classification*. Ellis Horwood, Chichester, 1994.
- [45] W.T. Miller, R.S. Sutton, P.J. Werbos. *Neural Networks for Control*. MIT Press, Cambridge, MA, 1990.
- [46] M. Minsky. Logical vs. Analogical or Symbolic vs. Connectionist or Neat vs. Scruffy. In: P. H. Winston, editor. *Artificial Intelligence at MIT, Expanding Frontiers*, Vol 1, MIT Press, Cambridge, MA, 1990. Reprinted in AI Magazine, 1991.
- [47] M. Minsky. *The Society of Mind*. Simon and Schuster, NY, 1987.
- [48] E.A. Nadaraya. On estimating regression. *Theory Probab. Applic.* 10: 186-90, 1964.
- [49] M.C. Nelson and W.T. Illingworth. *A Practical Guide to Neural Nets*. Addison-Wesley, Reading, MA, 1991.
- [50] D. Nguyen and B. Widrow. The truck backer upper: An example of self-learning in neural networks. *International Joint Conference on Neural Networks*. Washington, D.C.: II: 357-363, 1989.
- [51] A.-P. Refenes, editor. *Neural Networks in the Capital Markets*. J. Wiley, NY, 1995.
- [52] B.D. Ripley. *Pattern Recognition and Neural Networks*. Cambridge University Press, Cambridge, 1996.
- [53] D.E. Rumelhart and J.L. McClelland. Learning the past tenses of English verbs. In: D.E. Rumelhart and J.L. McClelland, editors. *Parallel Distributed Processing*, vol 2, Bradford Books/MIT Press, Cambridge, MA, 1986.
- [54] T.J. Sejnowski and C.R. Rosenberg. Parallel networks that learn to pronounce English text. *Complex Systems*, 1: 145-168, 1987.
- [55] D.F. Specht. A generalized regression neural network. *IEEE Transactions on Neural Networks*, 2, Nov. 1991, 568-576, 1991.
- [56] D.F. Specht. Probabilistic neural networks. *Neural Networks*, 3: 110-118, 1990.
- [57] R.R. Trippi and E. Turban. *Neural Networks in Finance and Investing*. Irwin Professional Publishing, Chicago, 1993 (1996 2nd edition).
- [58] M. Usher, M. Stemmler, C. Koch, and Z. Olami. Network amplification of local fluctuations causes high spike rate variability, fractal firing patterns and oscillatory local field potentials. *Neural Computation*, 6: 795-836, 1994.
- [59] A. Waibel and K. Lee. *Readings in Speech Recognition*. Morgan Kaufmann, CA, 1990.

- [60] G.S. Watson. Smooth regression analysis, *Sankhya*, Series A, 26: 359-72, 1964.
- [61] B. Widrow and S.D. Stearns. *Adaptive Signal Processing*. Prentice Hall, Englewood Cliffs, NJ, 1985.
- [62] A.S. Weigend and N.A. Gershenfeld, editors. *Time Series Prediction: Forecasting the Future and Understanding the Past*. Addison-Wesley, Reading, MA, 1994.
- [63] M. Zeidenberg. *Neural Networks in Artificial Intelligence*. Ellis Horwood, Ltd., Chichester, 1990.
- [64] J. Zupan and J. Gasteiger. *Neural Networks for Chemists. An Introduction*. VCH Verlagsgesellschaft, Weinheim, 1993.

Niektoré časopisy týkajúce sa neurónových sietí a umelej inteligencie:

Neural Networks, Pergamon Press  
 Neural Computation, MIT Press  
 IEEE Transactions on Neural Networks, Institute of Electrical and Electronics Engineers (IEEE)  
 Network: Computations in Neural Systems, Institute of Physics (Bristol, UK)  
 International Journal of Neural Systems, World Scientific Publishing  
 International Journal of Neurocomputing, Elsevier Science Publishers  
 Neural Network World, IDG Czechoslovakia  
 Computer Simulations in Brain Science, Springer Verlag  
 International Journal of Neuroscience, Springer Verlag  
 Neural Network Computation, Springer Verlag  
 Neural Computing and Applications, Springer Verlag  
 Complex Systems, Complex Systems Publications  
 Biological Cybernetics (Kybernetik), Springer Verlag  
 The Behavioral and Brain Sciences, Cambridge University Press  
 Journal of Complex System, USA: World Scientific Publishing Co.  
 INTELLIGENCE - The Future of Computing, Intelligence.