

UMĚLÉ NEURONOVÉ SÍTĚ

doc. RNDr. Petr Tučník, Ph.D.

petr.tucnik@fpf.slu.cz




OBSAH PŘEDNÁŠKY

- Studium neuronových sítí
- Historický vývoj
- Aplikace neuronových sítí

STUDIUM NEURONOVÝCH SÍTÍ



NEURONY



Zdroj: <http://neuron.tym.sk/>

0 NEURONOVÝCH SÍTÍCH

- Neuronové počítače jsou – zjednodušeně – matematickými modely neuronových systémů živých organismů.
- Dva základní směry výzkumu:
 - Pochopení a modelování fungování lidského mozku
 - HW realizace inspirovaná neurofyziologickými poznatky

ZAŘAZENÍ NEURONOVÝCH SÍTÍ

- Z hlediska způsobu práce s informacemi rozlišujeme dvě úrovně
 - Symbolická (např. logika)
 - Subsymbolická (neuronové sítě, genetické algoritmy)
- Neuronové sítě patří do tzv. nové umělé inteligence (tradiční UI je reprezentována směry jako expertní systémy, propoziční logika, stavové prostory apod.)


ROZDĚLENÍ SÍTÍ

- Z hlediska aplikace na řešení problému můžeme hovořit o dvou typech algoritmů:
 - Klasifikátor – třídí (klasifikuje) vstupní data (např. rozpoznání tváří)
 - Řídící – zajišťuje kontinuální řízení nějaké činnosti (např. řízení vozidla)

UMĚLÉ NEURONOVÉ SÍTĚ - HISTORICKÝ VÝVOJ





POČÁTEK PRACÍ - 1943



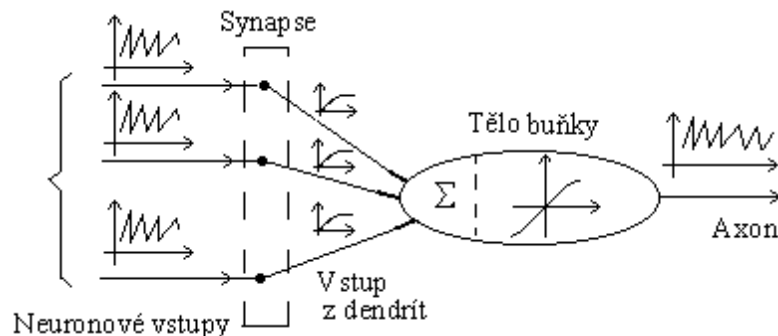
- V roce 1943 přišli pánové Warren McCulloch a Walter Pitts s **modelem jednoduchého neuronu**
- Neuron je fundamentální jednotkou každé neuronové soustavy
- Bylo dokázáno, že tento nejjednodušší typ modelů může počítat s libovolnou aritmetikou či funkcí.

BIOLOGICKÝ NEURON



FUNKČNÍ MODEL ZPRACOVÁNÍ SIGNÁLU V BIOLOGICKÉM NEURONU

- Z pohledu zpracování má model neuronu 3 základní části, které vykonávají specifické operace:
 - Synaptická spojení (přijímají informace).
 - Tělo buňky (soma) – je místem, kde se vykonávají operace agregace, prahování a nelineární transformace (aktivace) ze synaptických vstupů. Agregací se rozumí učení potenciálu neuronu. Jestliže potenciál neuronu přesáhne určitý práh, soma aktivuje výstupní signál.
 - Axon - prostřednictvím axonu je výstupní signál ze somy přenášen do synapsí jiných neuronů.



ROK 1949 – HEBBOVSKÉ UČENÍ



- V r. 1949 byla vydána kniha *The Organization of Behavior* od Donalda Hebba. Poskytla návod, kterak používat učící pravidlo pro synapse neuronů (interface).
- Inspirací byly podmíněné reflexy, které jsou pozorovatelné u živočichů.
- Myšlenky uvedené v této knize ovlivnily řadu vědců, ačkoliv 40.-50. léta nepřinesla v oblasti neurovýpočtů žádný zásadní pokrok.

NEUROPOČÍTAČ SNARK - 1951



- V roce 1951 byl Marvinem Minskym postaven neuropočítač SNARK.
- Z technického hlediska byl velmi úspěšný, automaticky adaptoval váhy, nikdy se ale nestal užitečným z hlediska praktické aplikace.
- Jednoduše vznikl, aby existoval.

PERCEPTRONY - 1957

- V roce 1957 byl model neuronu zobecněn Frankem Rosenblattem na tzv. **perceptron**, který počítal s reálnými čísly.
- Jedná se o pevnou architekturu jednovrstvé sítě s n vstupními a m výstupními neurony.
- Byl navržen i učicí algoritmus, který v konečném čase je schopen nalézt odpovídající váhový vektor parametrů nezávisle na počáteční konfiguraci.
- Reálné stavy neuronů ve vstupní vrstvě se nastavují na vstup sítě a výstupní neurony počítají svůj binární stav, který určuje výstup sítě stejným způsobem jako obecný neuron.



MARK I PERCEPTRON – 1958 (1)

- Na základě výzkumů o perceptronech byl v letech 1957-1958 sestaven Charlesem Wightmanem a Frankem Rosenblattem první neuropočítač s reálnou aplikací – rozpoznávání znaků.
- Znak se promítal na světelnou tabuli, která byla snímána maticí 20x20 fotosnímačů.
- Intenzita celkového počtu 400 snímačů byla vstupem do neuronové sítě perceptronů.
- Počítač měl odpovídat, zda se jedná o znak „A“ nebo „B“, atd.

MARK I PERCEPTRON – 1958 (2)

- Počítač také disponoval 512 adaptovatelnými váhovými parametry, které byly realizovány polem 8x8x8 potenciometrů.
- Hodnota odporu každého potenciometru odpovídala příslušné váze.
- Učící pravidlo řídil analogový obvod.
- Díky úspěchu při prezentaci se neuropočítače dostávají do popředí zájmu.



ADALINE

- Dalším typem neuronového prvku, který je podobný neuronu, je ADALINE (ADAptivní LINeární Element).
- Dynamika modelu se liší v tom, že výstupy sítě jsou obecně reálné a jednotlivé ADALINE realizují lineární funkci.
- Autory jsou Bernard Widrow a jeho studenti. Widrow se zasloužil o vznik první komerční organizace (Memistor Corporation) v pol. 60. let, která se zabývala stavbou neuropočítačů a jejich součástí.
- V r. 1960 byla založena (Rogerem Barronem a Leweyem Gilstrapem) firma zaměřená na aplikaci neurovýpočtů. Výsledky lze nalézt v knize Nilse Nilssona *Learning Machines* (1965).


BINÁRNÍ ASOCIATIVNÍ SÍŤE (PAMĚTI) (1)

- Model BAS byl vyvinut byl vyvinut na přelomu 50.-60. let Karlem Steinbuchem.
- Na rozdíl od klasických počítačových pamětí, kdy klíč k vyhledávání položky v paměti je adresa, dochází u asociativní paměti k vybavení určité události na základě její částečné znalosti.
- Zejména dva typy sítí zaznamenaly další rozvoj – **autoasociativní a heteroasociativní paměti.**

BINÁRNÍ ASOCIATIVNÍ SÍŤ (PAMĚTI) (2)

- Pro označení množiny neuronů používáme pojem pole. Na neuronovou síť se můžeme dívat jako na pole neuronů, které jsou topologicky seskupeny. Jednotlivé neurony mezi jednotlivými poli a v rámci polí jsou vzájemně v relaci prostřednictvím synaptických spojení.
- Má-li vstupní pole F_X celkem n neuronů a výstupní pole F_Y p neuronů, pak zobrazením vstupu x_1, x_2, \dots, x_n do výstupu y_1, y_2, \dots, y_p je možné definovat závislost

$$f: \mathbb{R}^n \rightarrow \mathbb{R}^p$$



BINÁRNÍ ASOCIATIVNÍ SÍŤE (PAMĚTI) (3)

- Váhy synaptických spojení lze reprezentovat maticí synaptických vah M pro synaptickou projekci z F_X do F_Y .
- Podobně označíme N matici vah pro zpětnou synaptickou projekci neuronů pole F_Y do pole F_X .

BINÁRNÍ ASOCIATIVNÍ SÍŤE (PAMĚTI) (4)

- Mají-li M , N stejnou strukturu, znamená to, že $M=N^T$ a $N = M^T$, kde M^T , N^T označují transpozici k matici M , N .
- V tomto případě mluvíme o dvojsměrných sítích (bidirectional).
- Vede-li aktivační dynamika neuronů v polích F_X a F_Y ke stabilnímu chování sítě, mluvíme o dvojsměrné asociativní paměti – BAM.

BINÁRNÍ ASOCIATIVNÍ SÍŤE (PAMĚTI) (5)

- BAM uchovává asociace mezi dvěma informacemi – přivedeme-li na vstup informaci X , na výstupu dostaneme asociaci Y a naopak.
- Specifický případ – jednosměrná síť. Vznikne, jestliže obě pole neuronů F_X a F_Y vzájemně splynou.
- Vznikne tak jedno pole neuronů, synapticky propojené samo se sebou.

BINÁRNÍ ASOCIATIVNÍ SÍŤE (PAMĚTI) (6)

- Matice synaptických propojení je čtvercová rozměru $n \times n$ nebo $p \times p$.
- Pokud je matice M symetrická, tj.
 $M = M^T$, pak jednosměrná síť definuje BAM.
- Zatímco BAM je heteroasociativní síť, po splynutí do jednoho pole F_Z vzniká autoasociativní síť.

DALŠÍ ROZVOJ OBORU

- Neuropočítače byly využívány stále pouze k experimentálním projektům.
- Rozvoji oboru nepřála ani malá publicita.
- Řada odborníků odchází do jiných oblastí výzkumu.

OBDOBÍ STAGNACE 1967-82

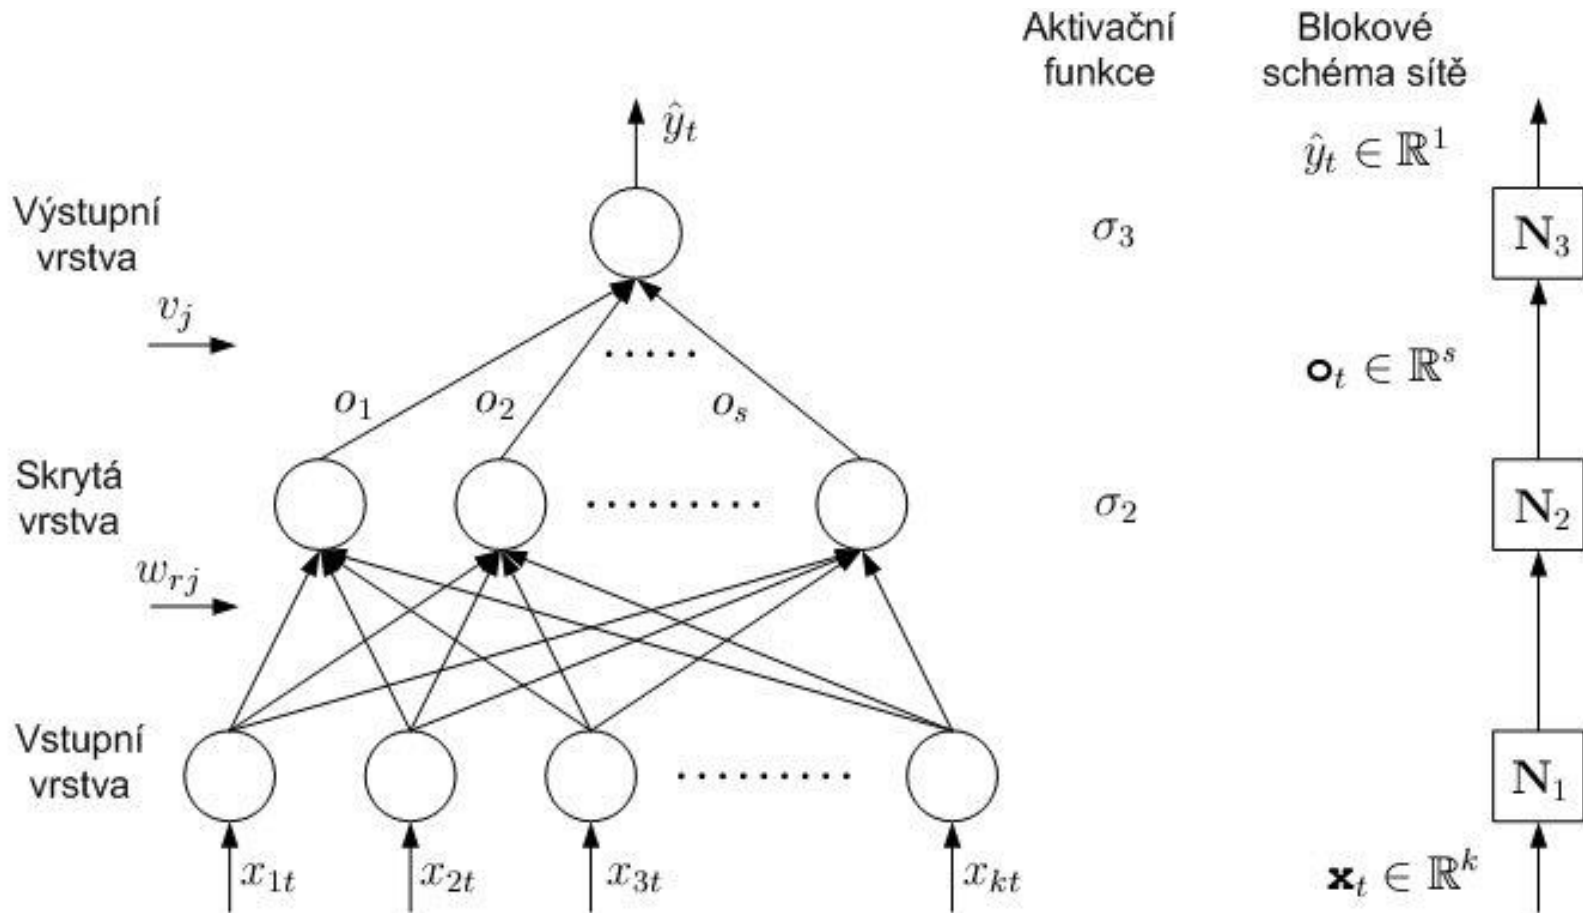
- Především dvě osobnosti se zasadily o dočasnou diskreditaci oboru neuronových sítí – Marvin Minsky a Seymour Papert.
- Kniha těchto dvou autorů *Perceptrons* upozornila na nemožnost perceptronu počítat funkci XOR.
- Nyní lze tento problém řešit vícevrstvou sítí, ale učící postupy (jak adaptovat jednotlivé váhy) nebyly v té době známy.
- Přísun financí do oboru se zbrzdil a projekty byly financovány především ze soukromých zdrojů.

DARPA – 80. LÉTA



- Objevuje se řada zajímavých talentů – Shun-Ichi Amari, James Anderson, Kunikiho Fukushima, Stephen Grossberg, Teuvo Kohonen, David Wilshaw.
- Vzniká řada grantových projektů zabývajících se neuropočítači a jejich využitím. Významná je zejména grantová agentura DARPA (Defense Advanced Research Project Agency).
- Nastává oživení v oboru neuronových sítí.

VÍCEVRSTVÉ SÍTĚ




HOPFIELDOVY SÍTĚ (1)



- John Hopfield ve svých pracích z let 1982 a 1984 ukázal souvislost některých modelů s fyzikálními modely magnetických materiálů.
- Podle něj byly později nazvány tzv. **Hopfieldovy sítě**, které fungují na principu autoasociativních pamětí. Hopfieldova síť má pevnou topologii s „n“ neurony, které jsou zapojeny cyklicky. Všechny neurony jsou zároveň výstupní.

HOPFIELDOVY SÍTĚ (2)

- Napravo je zobrazeno topologické schéma Hopfieldovy sítě se 4 neurony.
- Hopfieldova síť je model asociativní paměti, ve kterém pole neuronů splývají a existuje úplné obousměrné synaptické propojení neuronů.
- Zásadní podmínkou však je, aby síť byla asynchronní. to znamená, že každý neuron v síti vyhodnocuje své výstupy v časové na sobě nezávislých okamžicích na ostatních neuronech sítě. Pokud v určitém časovém okamžiku změní stav více jak jeden neuron, síť je nestabilní.



BACKPROPAGATION ALGORITHMUS – 1986 (1)

- Učící **backpropagation algoritmus** pro zpětné šíření chyby ve vícevrstvých sítích byl publikován v roce 1986 badateli sdruženými do skupiny PDP (Parallel Distributed Processing Group) jejímiž zástupci byli David Rumelhart, Geoffrey Hinton a Ronald Williams.
- Podařilo se jim vyřešit problém, který Minsky označil za nevyřešitelný a tím pozastavil vývoj v oboru.
- Stal se jedním z nejpoužívanějších algoritmů a je součástí až 80% všech neurosystémů.

BACKPROPAGATION ALGORITHMUS – 1986 (2)

- Model byl zobecněním sítě perceptronů pro acyklickou architekturu se skrytými vrstvami.
- Nejednalo se o nový objev, algoritmus byl původně objeven již v roce 1969 Arthurem Brysonem, Yu-Chi Ho, Paulem Werbosem a Davidem Parkerem.
- Systém úspěšně konvertoval anglicky psaný text na mluvený. Byl přímým konkurentem systému DECtalk, který obsahoval stovky pravidel vytvářených lingvisty po celá desetiletí.
- Již z tohoto malého příkladu je vidět nesporná síla neuropočítače.

BACKPROPAGATION ALGORITHMUS – 1986 (3)

- V podstatě se jedná o gradientní metodu minimalizující součet čtverců chyby výstupních hodnot uvažované sítě.
- Tento přístup lze aplikovat na libovolnou umělou neuronovou síť.
- Většinou se používá na vrstevnaté NS s dopředným šířením signálu bez laterálních vazeb mezi výkonnými prvky jednotlivých vrstev.

BACKPROPAGATION ALGORITHMUS – 1986 (4)

- Proces učení zpětným šířením je možno rozdělit do tří částí:
 1. Dopředné šíření signálu
 2. Zpětné šíření analýzy odpovídajících chyb
 3. Adaptování vhodných parametrů sítě
- Části 2 a 3 často splývají.

PRVNÍ KONFERENCE ZABÝVAJÍCÍ SE NEURONOVÝMI SÍTĚMI - 1987

- První konference se konala v San Diegu. IEEE mezinárodní konference hostila přes 1700 účastníků.
- Výsledkem bylo založení mezinárodní společnosti pro výzkum neuronových sítí INNS (International Neural Network Society).
- Vznikla řada časopisů jako *Neural Networks*, *Neural Computation*, *IEEE Transactions on Neural Networks*.

NEURONOVÉ SÍTĚ Z HLEDISKA REPREZENTACE POZNATKŮ

- Nejčastější námitkou proti NS vycházejí z nesrozumitelnosti způsobu, jímž jsou reprezentovány uložené informace.
- NS se v tomto ohledu chová jako černá skříňka – „není do ní vidět“.
- Vyplývá to z distribuovaného rozložení informací v rozsáhlých maticích vah
- Je to v ostrém kontrastu ke způsobu, jakým jsou ukládána data např. v jasně definovaných strukturách tradiční umělé inteligence – logika, ES...

APLIKACE NEURONOVÝCH SÍTÍ



TYPICKÉ OBLASTI APLIKACE NS

- Základní oblasti využití umělých NS
 - Analýza a zpracování jednorozměrných signálů
 - Predikce časových řad
 - Kompresi signálů
 - Zpracování obrazu
 - Filtrace šumu

ANALÝZA A ZPRACOVÁNÍ JEDNOROZMĚRNÝCH SIGNÁLŮ

- NS se aplikují tehdy, když je zapotřebí pracovat se signály, jejichž periodičita není zcela přesná, náhodně se mění a kdy je též třeba adaptivně podle potřeb uživatele měnit podmínky analýzy a požadavky na ni kladené.
- Analýza má obvykle charakter klasifikace příslušnosti jednotlivých částí sledovaného signálu do některé z hledaných tříd (např. vyhledávání významných složek elektrokardiografického signálu (EKG)).

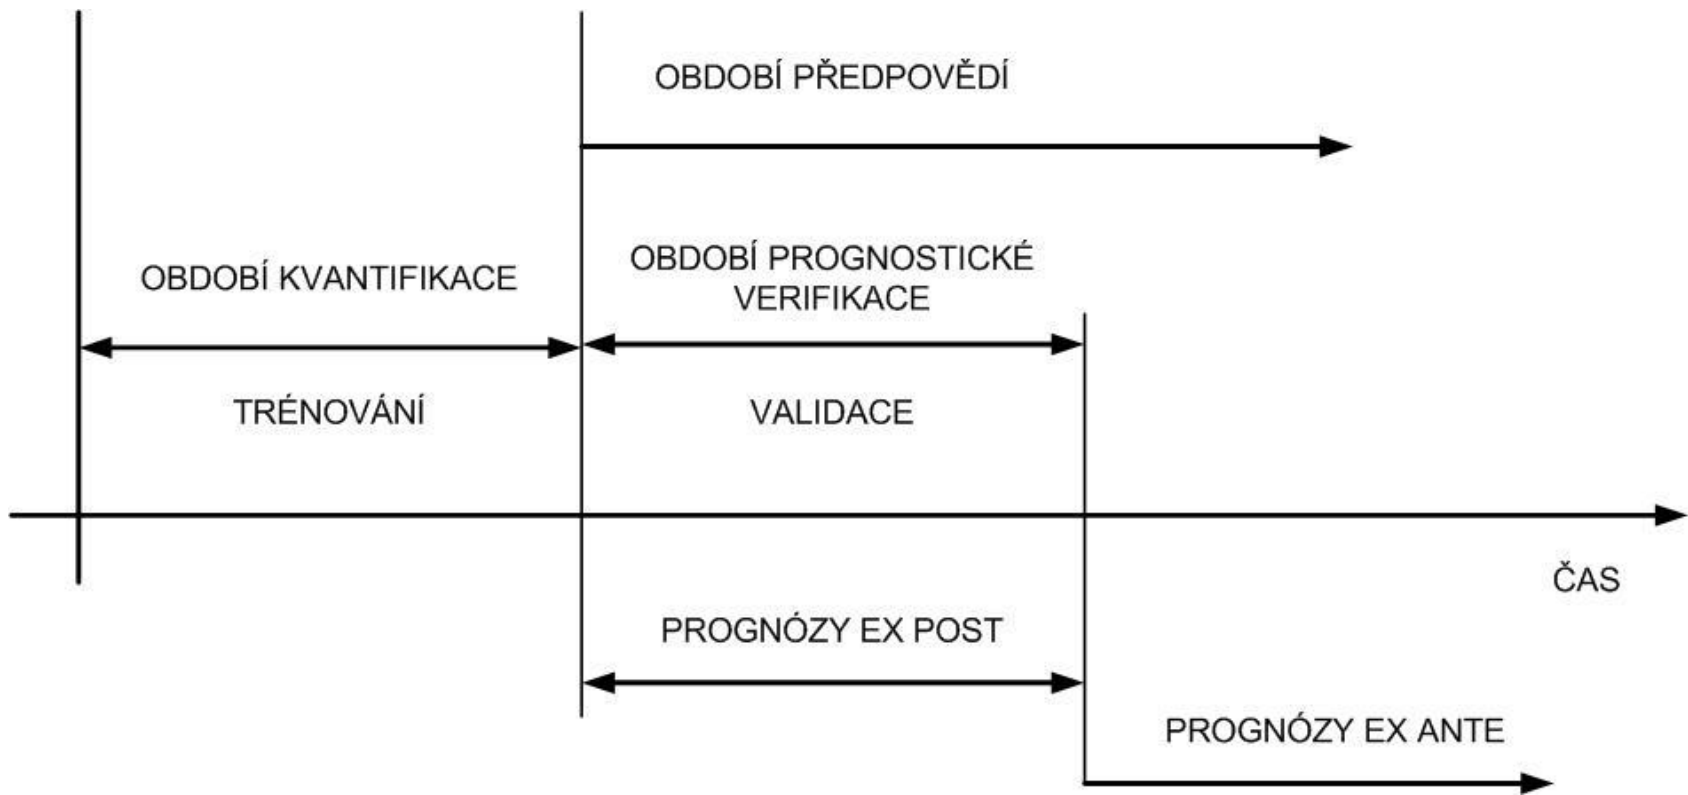
PREDIKCE ČASOVÝCH ŘAD (1)

- Často je potřebná znalost budoucího chování různých veličin
- Aplikace NS pro predikci časových řad:
 - Vývoj zdravotního stavu pacienta
 - Pohyb kurzů měn v dalším časovém období
 - Spotřeba elektrické energie v následujících 48 hodinách
 - Predikce hustoty provozu v dané dopravní lokalitě

PREDIKCE ČASOVÝCH ŘAD (2)

- Oproti tradičním metodám nabízejí NS výhodu při zpracování zejména komplikovaných dat:
 - Zašumělá data
 - Vícerozměrná data
 - Nelineární data
- Přesnost predikce se snižuje, když se pokoušíme předvídat dále v budoucnosti

PREDIKCE ČASOVÝCH ŘAD (3)



PREDIKCE ČASOVÝCH ŘAD (4)


- Prognózy EX POST (také pseudoprognózy) jsou takové prognózy, u kterých známe skutečnosti pozorování a jsme pro ně schopni vyčíslit chybu prognózy.
- Prognózy EX ANTE (v nejbližším horizontu) mají smysl pro praktické rozhodování, jelikož skutečně umožňují odhadovat vývoj.
- Dá se říci, že jestliže prediktor produkuje chybově přijatelné ex post prognózy, bude produkovat i chybově přijatelné ex ante prognózy.

KOMPRESSE SIGNÁLŮ (1)

- Neuronové metody komprese lze použít jak na jednorozměrné, tak vícerozměrné signály.
- Současně s kompresí je signál i zakódován.
- Princip komprese jednorozměrného signálu funguje tak, že síť má jedinou skrytou vrstvu, která je uspořádána tak, že počet neuronů vstupní a výstupní vrstvy je shodný a značně větší než počet prvků ve skryté vrstvě.


KOMPRESI SIGNÁLŮ (2)

- Vstupní signál X je přiváděn na vstup.
- Při učení je tentýž signál přiváděn i na výstupní vrstvu (Y).
- Přitom usilujeme o to, aby platilo $X=Y$
- Na prvcích skryté vrstvy je pak možno indikovat komprimovaný signál.



KOMPRESI SIGNÁLŮ (3)

- Takto naučenou síť rozdělíme řezem podél skryté vrstvy na dvě.
- Získáme tak dvě sítě, které od sebe můžeme vzdálit.
- Na místě vysílání i příjmu tak budeme mít k dispozici NS schopnou se signálem pracovat.
- Je však zapotřebí zajistit co nejmenší přenosové zkreslení signálu.



ZPRACOVÁNÍ OBRAZU

- Pro jednoduchost předpokládejme černobílé obrazové symboly, které nemají polotónový charakter.
- První částí úlohy je lokalizace rozpoznávaného znaku a jeho obklopení vhodným okolím, ve kterém je proveden rozklad na posloupnost jednoduchých signálů (většinou 0 a 1, podle toho, zda je daný obrazový element černý či bílý)
- Takový signál je vstupem do NS, ve které je provedena klasifikace do jemu příslušející třídy.
- Klasicky se takto rozpoznávají značky (dopravní, mapové, navigační), číslice, písmena, písmo.
- Nověji se rozpoznávají tváře nebo postavy.

FILTRACE ŠUMU (1)


- Šum se obvykle projevuje v jiných kmitočtových pásmech než užitečný signál. Vhodným potlačením těchto kmitočtových šumových pásem se vlastní signál příliš nezkrasí.
- Využívají se k tomu tzv. transversální filtry, které se svou strukturou v podstatě shodují s umělou NS ADALINE.
- Vlastnosti lineárních filtrů šumu je možno zlepšit aplikací nelineárních metod vycházejících z vrstevnatých sítí s nelineárními přenosovými funkcemi výkonných prvků.

FILTRACE ŠUMU (2)

- Značení k obrázku:
 - Zašuměný signál X
 - Šum N
 - Užitečný signál S
- Na vstupní vrstvu je přiváděn zašuměný signál

$$X = \{x\} = N+S$$

(směs užitečného signálu a šumu)



FILTRACE ŠUMU (3)

- Ve fázi učení je požadovaným výstupem nezašuměný signál S .
- Při procesu učení je síť natrénována na daném učebním souboru k rozlišování užitečných signálů a šumu.
- Je-li pak na vstup takto naučené sítě přiveden jiný zašumělý signál, zkreslený šumem podobného charakteru, objeví se na výstupu signál do značné míry zbavený rušivých složek.

DALŠÍ OBLASTI VYUŽITÍ NS

- Aplikace umělých NS v praxi
 - Řízení (např. ALVINN)
 - Analýza dat a znalostní systémy
 - Optimalizace
 - Aplikace v robotice
 - Finanční trhy
 - Kognitivní architektury

VIDEA A MATERIÁLY O UNS

- Deep learning v UNS:
<https://www.youtube.com/watch?v=BR9h47Jtqyw>
- Tutoriál / cyklus přednášek o UNS (37 videí):
<https://www.youtube.com/watch?v=xbYgKoG4x2g&list=PL3EA65335EAC29EE8>
- MIT – online kurzy k UNS (v rámci OpenCourseWare)
- Spousta odkazů na další zdroje také např. na [wikipedii](#), v online odborných databázích knihovny UHK, aj.

DĚKUJI ZA POZORNOST



POUŽITÁ LITERATURA

- Novák, M. et al: Umělé neuronové sítě – teorie a aplikace (1998)
- Marček, D.: Neuronové sítě a fuzzy časové řady (2002)