

A satellite with a yellow body and large solar panels is shown in orbit above the Earth's blue and white surface. The satellite is oriented towards the viewer, with its solar panels extended outwards. The Earth's curvature is visible in the background.

Dálkový průzkum Země



Ústav geoinformačních technologií
Lesnická a dřevařská fakulta MENDELU

Klasifikace založené na strojovém učení

- Strojové učení je podoblastí umělé inteligence, zabývající se algoritmy a technikami, které umožňují počítačovému systému '**učit se**'.
- Učením v daném kontextu rozumíme takovou změnu vnitřního stavu systému, která zvýší schopnost přizpůsobení se změnám okolního prostředí.
- Pro klasifikaci dat dálkového průzkumu Země se nejčastěji používají:
 - **neuronové sítě** (Artificial Neural Networks, ANN)
 - **rozhodovací stromy** (Decision Trees)


NEURONOVÉ SÍTĚ

- Neuronové sítě jsou výsledkem přírodního vývoje. Výborně se osvědčily ve složitých biologických systémech. Živé organismy vybavené neuronovou sítí se dovedou chovat adaptivně. To je dáno tím, že neuronová síť je schopna učit se. Učení se znamená dělat závěry ze zkušeností.
- Pokud vypadnou některé z neuronů dodávajících informace, výsledné chování neuronové sítě se nezmění.



Snímek neuronu v elektronovém mikroskopu

- Neuronové sítě jsou černé skřínky, do kterých vstupují data a na výstupu vycházejí data zpracovaná, závislá na datech vstupních. Tyto sítě jsou složeny z jednotlivých **neuronů**.
- Každý neuron má **mnoho vstupů a jeden výstup**. Vstupy se nazývají **dendrity** a jsou připojeny na výstupy (**axony**) jiných neuronů.
- K přenosu informací dochází na spojeních – synapsích.
- V lidském mozku má jeden neuron spojení v průměru asi s 10 tis. -100 tis. neurony.



Biologický neuron

Hebbův zákon učení


- Kanadský psycholog
- Zákon učení z r. 1949
- Dva spojené neurony:
 - oba jsou aktivní: vazba se zesiluje
 - oba jsou neaktivní: vazba se zeslabuje
 - jeden aktivní, druhý neaktivní: žádná modifikace vazby
- 1943 – první matematický model neuronu (McCulloch a Pitts)

UMĚLÉ NEURONOVÉ SÍTĚ

- Biologická síť neuronů se stala inspirací vědců k vytvoření umělé neuronové sítě
- Neurofyzilogické poznatky umožnily vytvořit zjednodušené matematické modely, které se dají využít pro neurovýpočty při řešení praktických úloh z oblasti umělé inteligence
- Nejde o kopii lidského mozku, ale o napodobení jeho základní funkce
- Mozek se učí tím, že upevňuje spojení mezi neurony nebo navazuje nová spojení
- Nervová buňka obdrží impuls od několika sousedních neuronů, energii sčítá a pokud dojde k překročení určité prahové hodnoty, signál pošle dál

Formální neuron - model umělého neuronu

- *Dendrity* - reprezentují místo vstupu signálu do těla neuronu.
- *Tělo neuronu* - sčítá signály dané okolními neurony. Takto stanovený vnitřní potenciál vede k excitaci (vybuzení) neuronu.
- *Axonové vlákno* - přináší signál daný stupněm excitace k synapsí.
- *Synapse* - tvoří výstupní zařízení neuronů, které signál zesilují či zeslabují a předávají dalším neuronům.
- Uměle vytvořený neuron funkčně odpovídá svému biologickému vzoru a tvoří základní "výpočetní jednotku" složitějšího komplexu - neuronové sítě



Srovnání počítač x lidský mozek (Hlaváč 2006)

	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

Obecně můžeme neuron formálně popsat podle vztahu :

$$y = f \left(\sum_{i=1}^N w_i x_i + \Theta \right)$$

kde y je výstup neuronu

x_i vstupy neuronu (celkem N)

w_i synaptické váhy


f nelineární přenosová funkce neuronu

Θ práh

Výraz v závorce vztahu se někdy označuje jako **vnitřní potenciál neuronu u** .

Váhy w_i u každého neuronu představují jeho **lokální paměť**; spojením všech neuronů dostáváme **celkovou paměť** sítě.

Učení sítě se provádí změnou těchto vah, ale také tvarováním přenosové funkce, změnou počtu neuronů v síti, popřípadě i topologickým uspořádáním sítě.



Model neuronu (McCulloch-Pitts)


Vlastnosti umělé neuronové sítě

- Umělá neuronová síť představuje distributivní, adaptivní, obecně nelineární stroj se schopností učení, který je sestaven z mnoha různých prvků pro zpracování informace.
- Při provádění výpočtů využívají neuronové sítě distribuované, paralelní zpracování informace - ukládání, zpracování a předávání informace probíhá prostřednictvím celé neuronové sítě.
- Každý prvek je spojen s jinými prvky nebo také sám se sebou pomocí zpětné vazby.
- Základním prvkem, tj. "výpočetní jednotkou" neuronové sítě je umělý neuron. Sílu signálů lze reprezentovat reálnými čísly, a proto lze popsat neuronovou síť matematicky.
- Hodnoty signálů přenášených mezi jednotlivými prvky se mění v závislosti na nastavitelných parametrech, které se nazývají **váhy**, w_{ij} . Prvek sčítá všechny příchozí hodnoty vážených spojení a produkuje výslednou hodnotu, která je nelineární (statickou) funkcí jeho součtu.

- Výstup prvku může být výstupem systému nebo může být zaslán na stejný nebo jiný prvek. Výstup neuronové sítě závisí na spolupráci mezi jednotlivými neurony uvnitř sítě.
- Specifickou vlastností neuronových sítí je to, že jsou schopny pracovat i když některé z neuronů nefungují, protože zpracování spoléhá na kolektivní výsledek funkce jednotlivých neuronů. Znamená to, že neuronové sítě jsou poměrně odolné proti poruchám a chybám.
- Důležitou vlastností neuronových sítí je schopnost učení. Znalosti jsou ukládány především prostřednictvím síly vazeb mezi jednotlivými neurony.
- Počet neuronů a jejich vzájemné propojení v síti určuje **architekturu (topologii)** neuronové sítě.
- Neuronová síť se v čase vyvíjí, mění se stav neuronů, adaptují se váhy.

- **Dynamika sítě:**


- Organizační – změna topologie
- Aktivní – změna stavu
- Adaptivní – změna konfigurace



- **Organizační dynamika**
 - Specifikuje architekturu neuronové sítě a její případnou změnu
 - Architektura sítě: propojení sítě, počet vrstev
 - Cyklická (**rekurentní**) síť, acyklická (dopředná, **feed-forward**) síť
- **Aktivní dynamika**
 - Specifikuje počáteční stav sítě a způsob jeho změny v čase při pevné topologii a konfiguraci
 - Aktivační funkce – postup, jakým se ze vstupů uzlů počítá jeho výstup (**sigmoidní fce**: skoková, standardní sigmoida, hyperbolický tangens,...)
- **Adaptivní dynamika**
 - Specifikuje počáteční konfiguraci sítě a způsob, jakým se mění váhové hodnoty na spojeních mezi jednotlivými neurony v čase
 - Adaptivní režim slouží k učení aktivační funkce - obvykle zadána tzv. tréninkovou množinou, iterační proces
 - Dva typy učení: **s učitelem** (chybové učení) a **bez učitele** (samoorganizace)
- Modifikace sítě může probíhat změnou synaptických vah, přizpůsobením přenosové funkce nebo změnou typologie

Práh neuronu Θ

- Práh resp. prahová hodnota znamená bariéru, kterou musí vstupní signál neuronu překonat, aby se mohl dál šířit neuronovou sítí.
 - Hodnota prahu tedy určuje, kdy je neuron aktivní resp. neaktivní.
 - Je-li hodnota vstupního signálu neuronu nižší než hodnota prahová, je na výstupu z neuronu signál odpovídající pasivnímu stavu neuronu.
- Jakmile dojde k překročení prahové hodnoty (tato prahová hodnota se může během procesu rovněž měnit), stává se neuron aktivním a výstupní signál z neuronu roste až do určité maximální hodnoty. Ta je dána oborem hodnot příslušné aktivační funkce.




Přenosová (aktivační) funkce neuronu f

- Úkolem přenosové (aktivační) funkce neuronu je převést hodnotu vstupního potenciálu na výstupní hodnotu z neuronu.
- Konkrétní tvary přenosových funkcí bývají velmi různorodé.
V principu se dají tyto funkce rozdělit na lineární a nelineární, případně na spojité a diskrétní.
- Výběr vhodné přenosové funkce je závislý na konkrétním typu řešené úlohy, případně na konkrétní poloze neuronu v neuronové síti.


Sigmoidální funkce	$f_s(u) = \frac{1}{1+e^{-u}}$
Hyperbolický tangens	$f_h(u) = \tanh(u)$
Znaménková funkce	$f_z(u) = \operatorname{sgn}(u)$
Heavisideova funkce	$f_H(u) = \begin{cases} 1 & \text{pro } u > 0 \\ 0 & \text{pro } u \leq 0 \end{cases}$

u vnitřní potenciál neuronu



Výstupní funkce $o(f)$

simuluje přenos signálu axonem. Tato funkce „dotváří“ konečnou hodnotu výstupu z neuronu.




- x_i vstupy neuronu (výstupy z předcházející vrstvy), $i = 1, 2, \dots, n$
- n počet vstupů (počet neuronů v předcházející vrstvě)
- w_j synaptické váhy
- y_a vstupní potenciál neuronu
- f aktivační funkce neuronu
- o výstupní funkce neuronu
- θ práh neuronu
- y výstup neuronu

Schéma umělého neuronu s výstupní funkcí

Struktura umělé neuronové sítě

- Struktura neuronové sítě se skládá z mnoha uzlů (neuronů) propojených směrovými spojeními. Spojení odpovídají signálům vstupujícím či vystupujícím z daného uzlu, který transformuje podle zadaného vztahu vstupní signály na jediný signál výstupní.
- Každý neuron může současně přijímat libovolný konečný počet různých vstupních signálů. Na další výkonné prvky může předávat libovolný konečný počet shodných informací o stavu svého výstupu.
- Alespoň část uzlů je adaptivní, tzn. že výstupy z nich závisejí na modifikovatelných parametrech.
- Cílem je nastavit tyto parametry tak, aby chování sítě minimalizovalo jisté kritérium. Uzly jsou seskupeny do jednotlivých vrstev.




Umělá neuronová síť se třemi neurony P_i

Vrstvená neuronová síť je tvořena minimálně třemi vrstvami neuronů: vstupní, výstupní a alespoň jednou vnitřní (skrytou) vrstvou.

Vždy mezi dvěma sousedními vrstvami se pak nacházejí tzv. úplná propojení neuronů. Taková síť je schopna aproximovat libovolnou matematickou funkci, přičemž přesnost této aproximace je tím větší, čím více neuronů síť obsahuje.

Zapojením dalších neuronů do sítě se může síť učit.




Vrstvená síť se vstupní vrstvou dimenze m , s výstupní vrstvou dimenze n a s r skrytými vrstvami (síť 4-6-6-6-3).

Učení umělé neuronové sítě

Proces nastavování parametrů sítě se nazývá učení. Podle způsobu učení dělíme neuronové sítě na dva základní typy: učení s učitelem a učení bez učitele.

Učení neuronové sítě s učitelem

Při učení s učitelem se umělá neuronová síť učí tak, že srovnává svůj výstup s výstupem požadovaným (učitel) nastavováním vah synapsí (hodnoty v matici) tak, aby se snížil rozdíl mezi skutečným a požadovaným výstupem. (Požadovaný výstup odpovídá dané trénovací množině.)



Jestliže je síť správně naučená a trénovací množina dat dostatečně charakterizuje celou množinu dat, pak je pravděpodobné, že neuronová síť se bude chovat “rozumně” i pro data, na kterých nebyla učena.


Rozlišují se dva typy algoritmů učení s učitelem. Při **učení off-line** (po dávkách) se mění hodnoty parametrů sítě až po průchodu celé trénovací množiny dat. Při **učení on-line** (učení vzorek po vzorku) se parametry sítě modifikují po průchodu každého vzorku dat z trénovací množiny. V praxi se oba způsoby často kombinují.

Učení sítě **bez učitele**


Síť nemá žádný srovnávací signál k určení správnosti. Váhy spojení se nastavují tak, aby síť poskytovala odezvu při stejných nebo podobných vstupních vektorech. Algoritmus hledá ve vstupních datech vzorky s určitými vlastnostmi podle závislosti, korelace.

Tak je např. možno analyzovat jaký vliv má roční období na burzu, počet myší na úrodu, apod.

Učení bez učitele se označuje jako **samoorganizace** (viz např. Kohonenova síť, síť ART). Pracovní metodou je **shlukování**. Podobná vstupní data aktivují neurony, které jsou blízko sebe.




Nejznámější neuronové sítě používané ke zpracování dat DPZ



Lineární asociativní paměť (LAM)

- jednovrstvá síť s dopředným šířením a pevnými vahami
- Vstupní vektory mohou být binární (0/1), popř. reálné
- Používá se např. k rekonstrukci neúplných a šumem poškozených obrazů



Výstupní hodnoty neuronů:

– pro reálné vstupy


$$y_i = \sum_{j=1}^N w_{ij}x_j, \quad \text{pro } i = 1, \dots, M$$

– pro binární vstupy

$$y_i = f_{\Pi}\left(\sum_{j=1}^N w_{ij}x_j - \Theta_i\right), \quad \text{pro } i = 1, \dots, M$$

Hopfieldova síť

- Jednovrstvá rekurentní síť s pevnými vahami
- Vstupní vektory musí být binární (0/1), popř. bipolární (-1/1)
- Používá se jako asociativní paměť, pro rekonstrukci neúplných a šumem poškozených obrazů a k optimalizačním problémům




Neuronová aktivační funkce:

- funkce jednotkového skoku $f_H(u) = \begin{cases} 1 & u > 0 \\ 0 & u \leq 0 \end{cases}$
- znaménková funkce (pro bipolární vstupní vektory)


Jednoduchý perceptron

- Jednoduchý neuron s dopředným šířením
- Síť má n vstupů a jeden pracovní neuron spojený se všemi svými vstupy
- Každému spojení je přiřazena určitá váha
- Přenášený signál je buď binární (0,1) nebo bipolární (-1,0,1)
- Učení s učitelem
- Neuronová aktivační funkce: znaménková funkce, jednotkový skok
- Klasifikátor pro lineárně separovatelné obrazy




Vícevrstvý perceptron

- Vícevrstvá síť s dopředným šířením
- Učení s učitelem
- Neuronová aktivační funkce: sigmoidální funkce, hyperbolický tangens (popř. jiná nelineární spojitá funkce)
- Použití: klasifikace obrazů, aproximace funkcí, predikce časových řad




Kohonenova síť

- Jednovrstvá síť s dopředným šířením
- Poprvé popsána r. 1982, nejdůležitější architektura ze strategie soutěžního učení – tj. učení bez učitele
- Vstupní vektor: $X = [x_1, \dots, x_N]^T, \quad x_i \in \mathbb{R}$
- Výstupní hodnota neuronů je definována jako vzdálenost mezi vstupním a váhovým vektorem:
$$y_i(t) = \sum_{j=1}^N (x_j(t) - w_{ij}(t))^2$$
- Použití: shlukování, analýza dat, vytváření sémantických map




Síť ART (Adaptive Resonance Theory)

- Dvouvrstvá rekurentní síť
- Učení bez učitele
- Vstupní vektor X : binární pro model ART-1, reálný pro model ART-2
- NS se většinou neumí naučit novou informací bez poškození informace již dříve naučené (proměnná stabilita sítě), ovšem:
- Asociativní NS přepínají mezi tvárným (učícím) a stabilním stavem aniž by došlo k poškození již naučené informace
- Použití: shlukování, rozpoznávání znaků, řečových segmentů atp.




Zpětné šíření chyby (error back-propagation)

- Pravděpodobně nejrozšířenější způsob propojení neuronů se sigmoidní funkcí jsou vícevrstevné sítě, je používán v 80% NS
- 3 etapy:
 - dopředné (feedforward) šíření vstupního signálu tréninkového vzoru
 - zpětné šíření chyby
 - aktualizace váhových hodnot na spojeních
- Během adaptace neuronové sítě jsou srovnávány vypočítané aktivace s definovanými vstupními hodnotami pro každý neuron ve výstupní vrstvě a pro každý tréninkový vzor. Na základě tohoto srovnání je definována chyba neuronové sítě, pro kterou je vypočítán faktor, který se šíří zpět k neuronům z předcházející vrstvy.



- Algoritmus backpropagation zohledňuje při výpočtu nejen změny vah ve směru gradientu chybové funkce, ale navíc i předešlou změnu, tzv. moment (hybnost).
- Moment určuje míru vlivu předchozí změny, obvykle se volí 0,9 (0-1)
- Pomocí momentu gradientní metoda lépe opisuje tvar chybové funkce, protože bere do úvahy předchozí gradient
- Architektura vícevrstevné NS – tj. určení vhodného počtu vnitřních neuronů a jejich spojení – by měla odpovídat složitosti řešeného problému, tj. počtu tréninkových vzorů, jejich vstupů a výstupů a struktuře vztahů, které popisují
- Malá síť nemůže řešit komplikovaný problém
- Bohatá architektura – s větším počtem vah roste výpočetní náročnost adaptace

- Nalezená konfigurace sítě obvykle příliš zobecňuje tréninkové vzory, tj. špatně generalizuje. Tomuto přesnému zapamatování tréninkové množiny bez zobecnění zákonitostí v ní obsažených se říká **přeučení** (overfitting).
- Pro test kvality generalizace neuronové sítě se počítá chyba sítě vzhledem k tzv. testovací množině, což je část tréninkové množiny, která se záměrně nevyužila k adaptaci



Neuronové klasifikátory v Idrisi 15 Andes a 16 Taiga

- Programové balíky Idrisi 15 Andes a 16 Taiga obsahují tři klasifikátory, založené na automatizovaném strojovém učení a neuronových sítích.

Jsou to:

- Vícevrstvý perceptron ► Multi-Layer Perceptron – **MLP**
- Samoorganizující se Kohonenova síť ► Self-Organizing Map – **SOM**
- Fuzzy mapa dle adaptivní rezonanční teorie (Adaptive Resonance Theory, ART)
► **Fuzzy ARTMAP**

Vícevrstvý perceptron ► Multi-Layer Perceptron – MLP

MLP - Multi-Layer Perceptron Classifier

Classification options
☒ Train network ☐ Load weights

Band images

Band ID	Image name
Band 2	ch2green
Band 3	ch3red
Band 4	ch4nired

Number of files: 4

Insert layer group ...
Remove current file

Training site specification
☒ Image ☐ Vector
Training pixels per category: 100
Testing pixels per category: 100

Network topology
Input layer nodes: 4
Output layer nodes: 0
Hidden layers: 1
Layer 1 nodes: 1
Layer 2 nodes: 1

Training parameters
☐ Use automatic training
☐ Use dynamic learning rate
Learning rate: 0.010
End learning rate: 0.001
Momentum factor: 0.5
Sigmoid constant a: 1.0

Stopping criteria
RMS: 0.0001
Iterations: 10000
Accuracy rate: 100 %

Running statistics
Iterations:
Learning rate:
Training RMS:
Testing RMS:
Accuracy rate:

Output options
☒ Hard classification ☐ Perform confusion matrix analysis
☐ Map output activation levels ☒ Sigmoidal ☐ Linear
☐ Map hidden layer activation

Output file names
Hard classification image: LedniceMLP1
Activation level prefixes:
Output layer:
Hidden layer 1:
Hidden layer 2:

Train Stop Save weights
Classify Close Help

Pracovní postup

Nejprve je nutno zvolit způsob klasifikace.

Nabízejí se dvě možnosti:


- Trénování sítě (Train network)
- Zavedení existujícího souboru vah (Load weights)

Pracovní metody modulu MLP

Modul MLP umožňuje řízenou klasifikaci. Pro trénování sítě používá algoritmus **zpětného šíření chyby (error back-propagation)**.

Vrstvená neuronová síť obsahuje v tomto případě jednu vstupní vrstvu, jednu výstupní vrstvu a jednu nebo více skrytých vrstev. Funkce skrytých vrstev je analogická liniím, které umožňují přiřadit body v multispektrálním prostoru do příslušných klasifikačních tříd.

Zpětné šíření zahrnuje dva hlavní kroky, které umožňují modifikaci stavu neuronové sítě – **dopředné a zpětné šíření**. Výpočet závisí na informaci z trénovacích množin, na jejímž základě jsou opravovány váhy synapsí.



V průběhu trénovací fáze je každý vzorek (např. příznakový vektor odpovídající jednomu pixelu) přiveden do vstupní vrstvy a přijímací uzel (neuron) sumuje vážené signály ze všech uzlů se kterými je spojen v předcházející vrstvě.


Když je dopředný krok ukončen, výsledky na výstupních uzlech se porovnávají s očekávanými výsledky.

Každý výstupní uzel je sdružen s třídou. Když je vzorek (pattern) přiveden do sítě, každý výstupní uzel generuje hodnotu, která indikuje podobnost mezi vstupním obrazcem a odpovídající třídou.

Skutečný výstup se obvykle liší od výstupu očekávaného (tj. učitele); rozdíl odpovídá chybě sítě. Tato **chyba se pak zpětně šíří** s váhami korigovanými pro jednotlivá propojení na základě vztahu známého jako pravidlo delta:

$$\Delta w_{ji}(t+1) = \eta \delta_{ji} o_i + \alpha \Delta w_{ji}(t)$$

kde η je rychlost učení (learning rate), α je faktor hybnosti (momentum) a δ je vypočtená chyba.



Dopředné a zpětné kroky pokračují tak dlouho, až se síť „naučí“ charakteristiky všech tříd.

Cílem učení sítě je získat správné váhy pro spojení mezi vstupní vrstvou a skrytými vrstvami, a mezi skrytými vrstvami a výstupní vrstvou.


To pak umožňuje klasifikaci neznámých pixelů.

Klasifikace

Je možno nastavit výstup klasifikace jako:

- a) mapu tvrdé klasifikace
- b) mapy výstupních aktivačních úrovní
- c) mapy aktivačních úrovní skrytých vrstev.

Lze zvolit analýzu chybové matice (confusion matrix analysis), které umožňuje stanovit přesnost klasifikace.




MLP lze považovat za tvrdý i měkký klasifikátor.

Tvrdý klasifikační výsledek poskytuje mapu, ve které každý pixel náleží určité třídě.

Měkký klasifikační výsledek – mapy aktivačních úrovní poskytují skupinu obrazů zaznamenávající stupně příslušnosti každého pixelu ke každé možné třídě. Výstupem tedy není jednoduchá mapa klasifikace půdního pokryvu, ale soubor obrazů (jeden pro každou třídu).

Na rozdíl od map pravděpodobnosti, nemusí být úhrn hodnot pro každou polohu pixelů nutně 1. Je tomu tak proto, že výstupy z neuronové sítě se získávají pomocí zneostření (fuzzifying) signálů do hodnot v intervalu 0-1 prostřednictvím aktivační funkce. Vyšší hodnoty představují vyšší stupeň příslušnosti k odpovídající třídě.

Samoorganizující se Kohonenova síť ► Self-Organizing Map – SOM



Pracovní postup

1. Nejprve je nutno vybrat klasifikační variantu. Existují dvě možnosti:


- Řízená klasifikace (Supervised)
- Neřízená klasifikace (Unsupervised)

2. Potom se stanoví způsob klasifikace:

- Trénováním sítě (Train network)
- Použitím existujícího souboru vah (Use weights)

Modul SOM realizuje jak neřízenou (unsupervised) tak řízenou (supervised) klasifikaci obrazových dat dálkového průzkumu na základě **Kohonenovy samoorganizující se sítě**.

Jde o typ sítě, která při učení nepotřebuje učitele. Je založena na algoritmu shlukové analýzy. Algoritmus sítě má tj. schopnost nalézt určité vlastnosti na základě překládaných trénovacích dat, bez přítomnosti nějaké vnější informace.



Kohonenova síť má pouze dvě vrstvy.

Počet vstupů je roven dimenzi vstupního prostoru, v našem případě má hodnotu tři (první vrstva obsahuje pouze tři neurony).

Druhá vrstva je typicky uspořádána jako dvourozměrné (obvykle čtvercové) pole neuronů. Každý výstupní neuron je spojen se všemi neurony vstupní vrstvy synaptickými váhami.

Vlastní přenosovou funkci neurony nemají. Jedinou operací, kterou každý neuron v síti provádí, je výpočet vzdálenosti (odchylky) předloženého vzoru od vzoru zakódovaného ve vahách daného neuronu podle vztahu

$$d = \sum_{i=0}^{N-1} [x_i(t) - w_i(t)]^2$$

Trénování a klasifikace


1. Před klasifikací obrazových dat je nutno nejprve **natrénovat síť**.

- Po zavedení všech parametrů se zahájí trénovací proces pomocí volby Coarse tune.
- Lze pokračovat volbou Fine tune.
- Tlačítko U-matrix umožňuje zobrazit U-matici, která představuje mapu průměrné vzdálenosti neuronu k jeho sousedům. Tato matice je užitečná pro detekování existujících obrazců v analyzovaných snímcích.

Na konci trénovacího procesu lze uložit váhy do souboru (.som)

2. Vlastní **klasifikaci** lze realizovat:


- na základě parametrů vah dosažených trénováním sítě, nebo
- použitím již existujícího souboru vah.



Ukázka příznakové mapy pro tréninková data obsahující 12 tříd

Fuzzy mapa dle adaptivní rezonanční teorie (Adaptive Resonance Theory, ART)

► (Fuzzy ARTMAP)




Pracovní postup

1. Nejprve je nutno vybrat klasifikační variantu. Existují dvě možnosti:
 - Řízená klasifikace (Supervised)
 - Neřízená klasifikace (Unsupervised)
2. Potom se stanoví způsob klasifikace:
 - Trénováním sítě (Train network)
 - Použitím existujícího souboru vah (Use weights)

Modul Fuzzy ARTMAP realizuje jak neřízenou (unsupervised) tak řízenou (supervised) klasifikaci obrazových dat dálkového průzkumu. Algoritmus Fuzzy ART je shlukovací algoritmus, pracující s vektory s neostrými analogovými vstupními obrazci (reálná čísla v intervalu 0.0 a 1.0) a zahrnující inkrementální způsob učení. Ten umožňuje učení sítě bez zapomínání dříve dosažených výukových stavů.

Neuronovou síť založenou na adaptivní rezonanční teorii (Adaptive Resonance Theory, ART, vytvořili Grossberg a Carpenter (1991). Byla vyvinuta z biologické teorie zpracování kognitivní informace.



Fuzzy ARTMAP pro neřízenou klasifikaci má dvě vrstvy, F1 (vstupní vrstva) a F2 (vrstva kategorií). Tyto dvě vrstvy tvoří model ARTa. Vrstva F1 představuje vstupní příznakový vektor a obsahuje neurony pro každý příslušný rozměr. N-dimensionální vstupní vektor se zpracovává vztahem

$$I = (a, a^c) = (a_1, a_2, \dots, a_n, 1 - a_1, 1 - a_2, \dots, 1 - a_n)$$


Počet neuronů vrstvy F2 se stanovuje automaticky; začíná s jedním neuronem a v průběhu učení dynamicky roste.

Pro řízenou klasifikaci má Fuzzy ARTMAP dvě další vrstvy, vrstvu mapového pole (map field layer) a výstupní vrstvu. Tyto dvě další vrstvy tvoří model ARTb. Jak výstupní vrstva, tak vrstva mapového pole obsahují m neuronů, kde m je počet výstupních tříd. Mezi těmito dvěma vrstvami existuje spojení jedna k jedné. Parametr vigilance řídí „těsnost“ shluků.

Klasifikace

Před klasifikací obrazových dat je nutno nejprve natrénovat síť (volba **Train network**), nebo použít soubor s existujícími synaptickými vahami (Volba **Use weights**).

Vstupní informace osciluje ve formě výstupních hodnot mezi dvěma vrstvami neuronů dokud se nedosáhne rezonance. V tomto okamžiku začíná učení, tj. adaptace vah.



Architektura zjednodušené sítě ART

K rezonanci může dojít ve dvou případech:

(1) V případě, že síť už v minulosti zpracovávala stejný nebo velmi podobný vzorek, rezonance nastává okamžitě.

(2) V případě, že vstupní vzorek je odlišný ode všech předešlých, spouští se proces prohledávání naučených kódů a porovnává se jejich podobnost s prezentovaným vzorkem; přitom se definuje určitá prahová hodnota, která určuje minimální přípustnou podobnost vítězné třídy. Když tento práh nesplňuje žádná ze známých tříd, systém vytvoří novou třídu, identickou s předloženým vzorkem.

Tím se dosahuje jak stability-síť rezonuje v případě známého vstupu (viz 1), tak plasticity-síť má schopnost učit se nové neznámé vzorky (viz 2).

Neuronové klasifikátory v Idrisi 15 Andes a 16 Taiga - shrnutí

Vícevrstvý perceptron (Multi-Layer Perceptron – MLP)

Tato neuronová síť umožňuje řízenou klasifikaci. Pracuje s algoritmem zpětného šíření chyby. Zahrnuje práci v automatickém (meta-inteligentním) módu, progresivní modifikaci rychlosti učení, dvě skryté vrstvy a schopnost mapovat všechny aktivační vrstvy, včetně vrstev skrytých.

Samoorganizující se Kohonenova síť (Self-Organizing Map – SOM)

Tento neuronový klasifikátor lze použít ve variantě řízené i neřízené klasifikace. Síť bere v úvahu laterální interakce neuronů. Provádí projekci z vícerozměrného prostoru do prostoru s nižší dimenzí. Pro jemné nastavení sítě je k dispozici kvantování výukového vektoru (Learning Vector Quantization, LVQ).

Fuzzy mapa dle adaptivní rezonanční teorie ART (Fuzzy ARTMAP)

Tato neuronová síť poskytuje možnost řízené i neřízené klasifikace. Pracuje na základě teorie adaptivní resonance. Tato účinná operace vyžaduje minimum lidské interakce. Síť vykazuje stabilitu (rezonuje v případě známého vstupu) i plasticitu (schopnost učit se nové neznámé vzorky).



ROZHODOVACÍ STROMY

- Reprezentování znalostí v podobě rozhodovacích stromů dobře známe z řady oblastí. Připomeňme si nejrozumnější „klíče k určování“ různých živočichů, rostlin nebo minerálů.
- Indukce (postup od konkrétních případů k obecnému závěru) rozhodovacích stromů patří k nejznámějším algoritmům z oblasti symbolických metod strojového učení.
- Od kořene stromu se na základě odpovědí na otázky (umístěné v nekoncových, tj. nelistových uzlech) postupuje příslušnou větví stále hlouběji, až do koncového, tzv. listového uzlu, který odpovídá zařazení příkladu do třídy.

- Cílem rozhodovacích stromů je identifikovat objekty, popsané různými atributy, do tříd. Představit si je můžeme jako řádky v tabulce, kde jednotlivé sloupce jsou atributy (např. DN hodnoty). Jelikož se jedná o strom, algoritmus je velmi rychlý.
- Rozhodovací strom se musí nejprve vytvořit z množiny daných objektů, které musí někdo (učitel, jiný algoritmus) zařadit do skupin=tříd (skupina se obvykle označuje jako závislý atribut a zapisuje se do tabulky do posledního sloupce). Jedná se tedy o učení s učitelem.
- Každý uzel stromu představuje jednu (vybranou) vlastnost objektů, z tohoto uzlu vede konečný počet hran - větví. Proto je nutné vlastnosti nejdříve diskretizovat (např. z reálných čísel do konečného počtu intervalů).
- Hlavním problémem je vytváření takového stromu. Ten musí co nejlépe objekty od sebe odlišit. Pro kořenový uzel se proto vybírá takový atribut, který umožňuje co nejlepší rozlišení objektů. Při tom se jakožto parametr využívá entropie (míra informační hodnoty atributu).


Binární rozhodovací stromy

- Nejznámější jsou obecné binární rozhodovací stromy (OBCT = ordinary binary classification trees)
- rozdělují prostor do mnohoúhelníků, které mají strany rovnoběžné s osami
- posloupnost rozhodnutí je aplikována na jednotlivé příznaky
- rozhodování probíhá podle dotazů ve tvaru „je příznak $x_i \leq \alpha$?“
- postupným dělením prostoru vytvoříme oblasti, které odpovídají jednotlivým třídám:
- odpovídající binární strom:



Strom je složen z:

- **kořene** (root), který představuje počátek,
- **uzlů** (internode), které zajišťují spojení mezi kořenem, ostatními uzly a listy,
- **listů**, které znamenají rozhodnutí; v případě klasifikací obrazových dat jsou tvořeny skupinami pixelů zařazených do stejné třídy.



Zdroj: <http://ksp.mff.cuni.cz/tasks/18/k181.png>

Principy klasifikace

- Klasifikace pomocí rozhodovacích stromů generuje výstup v podobě binárního stromu, který se obvykle snadno interpretuje.
- Model rozhodovacích stromů obsahuje pravidla, umožňující dospět k cílovým proměnným.
- Klasifikační algoritmus poskytuje snadno pochopitelný popis distribuce zpracovávaných dat.
- Úplný binární stromový algoritmus umožňuje postupné binární štěpení datového souboru a tvorbu homogenních podmnožin.
- **Cílem je nalézt nějaký strom konsistentní s trénovacími daty.** Přitom se dává přednost menším stromům.

Růst a prořezávání rozhodovacího stromu

- Klasifikátor rozhodovacího stromu pracuje ve dvou fázích:
 - **fáze růstu** – tvorba rozhodovacího stromu
 - **fáze prořezávání** – redukce stromu, aby v listovém uzlu převažovaly příklady jedné třídy.
- Při tvorbě rozhodovacího stromu se postupuje metodou „rozděl a panuj“ (divide and conquer). Trénovací data se postupně rozdělují na menší a menší podmnožiny tak, aby v těchto podmnožinách převládaly příklady jedné třídy. Cílem je posoudit v každém uzlu příslušný atribut a najít takový výraz, který nejlépe rozdělí trénovací data v dané větvi. Hodnota tohoto výrazu závisí na tom, jak dobře separuje uvažované třídy.
- Po dokončení růstové fáze se vytvoří nový podstrom (prořezaný), založený na odstranění nejčastějších chyb. V této fázi dochází k odstraňování malých uzlů, které jsou důsledkem šumu v tréninkových datech
- Díky tomu pak dochází k přesnější klasifikaci neznámých dat.

Algoritmus růstu

1. Vezmi jeden atribut jako kořen dílčího stromu
2. Rozděl data na podmnožiny podle hodnot tohoto atributu
3. Nepatří-li všechna data v podmnožině do téže třídy, pro tuto podmnožinu opakuj postup od bodu 1.

Algoritmus prořezávání

1. Převeď strom na pravidla
2. Generalizuj pravidlo odstraněním podmínky z předpokladu, pokud dojde ke zlepšení odhadované přesnosti
3. Uspořádej prořezaná pravidla podle odhadované přesnosti; v tomto pořadí budou pravidla použita pro klasifikaci

Příklad aplikace rozhodovacího stromu (podle Dobrovolného, 2001)

Máme k dispozici multispektrální data družice Landsat TM , kde pro každý objekt (pixel) známe jeho hodnotu (atribut) v 6 různých částech spektra (TM1 až TM6).

U trénovacích dat navíc známe třídu, do které každý objekt spadá:

- Voda - vodní plochy
- Lesl - plochy s převahou listnatého lesa
- Lesj - plochy s převahou lesa jehličnatého
- Polev - plochy polí s vegetací
- Poleb - plochy polí bez vegetace
- Zast - zastavěné plochy

Výsledný strom může vypadat například takto (cílová třída objektu je uvedena v listu stromu (za dvojtečkou):

```
TM3 <= 35 :  
| TM4 > 99 : polev (12.0)  
| TM4 <= 99 :  
| | TM5 > 58 : lesl (30.0/1.0)  
| | TM5 <= 58 :  
| | | TM6 <= 12 : lesl (2.0)  
| | | TM6 > 12 : lesj (8.0)  
TM3 > 35 :  
| TM6 <= 23 : voda (17.0)  
| TM6 > 23 : poleb (26.0)
```



Např. pro objekt, jehož hodnoty atributů – DN hodnoty pixelů v jednotlivých pásmech – jsou (20,1,32,97,70,21), jsou splněny podmínky $TM3 \leq 35$, $TM4 \leq 99$ a $TM5 > 58$.

Proto bude tento pixel klasifikován do třídy lesl.

V závorkách za listem je uveden celkový počet objektů z učicí množiny, které spadají do tohoto listu, a počet objektů, které sem byly zařazeny chybně.



- Klasifikovaná oblast na barevné syntéze
- Výsledek klasifikace metodou maximální pravděpodobnosti (dole vlevo)
- Výsledek klasifikace metodou rozhodovacího stromu (dole vpravo)




Obecné rozhodovací stromy

- Pro vytvoření rozhodovacího stromu se mohou použít nejen spojité atributy, ale také atributy výčtové.
- Uzel ve stromu, který obsahuje výčtový atribut, bude mít tolik větví, kolika hodnot může atribut nabývat. Pak už se ovšem nejedná o binární strom.

Classification Tree Analysis (CTA) v Idrisi 16 Taiga

- Modul Classification Tree Analysis (CTA) umožňuje klasifikaci dat dálkového průzkumu i pomocných dat . Je vhodný pro mapování půdního pokryvu.
- CTA představuje jednorozměrnou **neparametrickou** techniku. Znamená to, že data sdružená s určitou třídou na základě určitého atributu nemusí odpovídat žádnému specifickému (např. normálnímu) rozdělení.
- Díky tomu může zpracovávat třídy s neobvyklými charakteristikami, jako jsou např. nepropustné povrchy obsahující prvky s vysokou odrazivostí (asfalt) i nízkou odrazivostí (beton). *Kdo zná příklad takového povrchu?*
- CTA postupně štěpí data tak, že vytváří homogenní podtřídy, jejich výsledkem je hierarchický strom rozhodovacích pravidel.



Problém klasifikace dat dálkového průzkumu rozhodovacími stromy

- Existence korelace mezi nezávislými proměnnými (což je v datech dálkového průzkumu obvyklé) vede k velmi komplexním stromům.
- Tomu se lze vyhnout, použije-li se dříve transformace metodou hlavních komponent (v Idrisi PCA) nebo metodou kanonických komponent (v Idrisi CCA).
- Klasifikační strom se tím zjednoduší, ale obvykle je obtížnější ho interpretovat.

Závěr ke klasifikaci metodami strojového učení

- Důležitá (z hlediska dobývání znalostí) je schopnost modelů strojového učení učit se z příkladů.
- U rozhodovacích stromů jsou nalezené znalosti uživateli srozumitelné (tzv. bílá skříňka).
- V neuronové síti jsou znalosti „rozprostřeny“ v podobě vah jednotlivých vazeb mezi neurony. Neuronová síť se chová jako černá skříňka; není příliš zřejmé, co se uvnitř děje.
- Je na uživateli stanovit, jakou metodu při své práci bude preferovat.

ZDROJE

- Eastman, J.R. 2009: Idrisi TAIGA Guide to GIS and Image Processing, Clark Labs, Worcester, MA
- Volná, E. 2002: Neuronové sítě 1. Ostravská univerzita, Přírodovědecká fakulta. Učební text.
- Vomlelová, M. 2006: Rozhodovací stromy. <http://kti.mff.cuni.cz/~marta/slistromy.pdf>
- Vyorálková, I. 2002: Zpracování snímku DPZ neuronovými sítěmi. Diplomová práce. Karlova Univerzita, Praha.
- Matoušek V., 2006: Umělá inteligence a rozpoznávání, část neuronové sítě.
- Veselovský M.: Neuronové sítě. <http://avari.cz/uir/index.php>
- <http://bio.felk.cvut.cz/~novakd/mws/doc/neuron/neursite.html>, viz NS5
- http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2001/Sbornik/Referaty/Dobrovolny.htm