


Metody umělé inteligence ve vodním hospodářství



Umělá inteligence

- Umělá inteligence (vědní disciplína) – **aproximace** určitých schopností živých organismů (intelektuálních schopností člověka)
- **Charakterický rys** umělé inteligence – těsné spojení s výpočetní technikou
- **Výpočetní technika:**
 - umožnila řešit numericky náročné úlohy
 - vedla k hledání kvalitativně nových a efektivnějších postupů často se snahou napodobit intelektuální schopnosti člověka (analýza různých jevů, logické usuzování, rozhodování v podmínkách neurčitosti)

Motivace rozvoje metod UI

- složitost objektivní reality
- neurčitost, která má různý charakter a původ (nahodilost, vágní popis veličin)


Fenomén neurčitosti

- výrazně ovlivňuje vývoj vědeckého výzkumu, který usiluje o řešení problémů měnícího se reálného světa
- někdy UI definována jako schopnost dosáhnout cíle nebo udržet požadované chování systému v neurčitých podmínkách

Důvěryhodnost matematických modelů – úzce spjata se složitostí a neurčitostí systémů (z důvodu krize dat nebo příliš dlouhé doby výpočtu, např. při operativním řízení různých systémů se používají jednodušší modely zvládnutelné numericky v přijatelném čase, které mají nižší důvěryhodnost)

Srážkoodtokový proces


Neurčitost - modelování srážkoodtokového procesu, operativní předpovídání a operativní řízení odtoku vody z povodí za povodňových situací



Projevy neurčitosti

- Schematizace povodí
- Automatizace měření a přenosu dat /průtoky, hladiny v nádržích, srážky/
- Předpovědi srážek /ALADIN, německý model, REEDING/
- Volba modelu, kalibrace modelu
- atd.

Schematizace povodí




Měřené a předpovězené srážky


Rozložení srážek - Horton



Meteorologický radar



Předpověď srážek - ALADIN



Dělení metod UI

Metody umělé inteligence:

- adaptivita
- učení (umělé neuronové sítě)
- genetické algoritmy
- fuzzy modely
- teorie rozpoznávání
- expertní systémy a znalostní inženýrství
- robotika
- komunikace se strojem v přirozeném jazyce

Adaptivita

Adaptivita

Schopnost živých organismů přizpůsobit se změnám okolního prostředí, a to hlavně když jsou nepříznivé.

Samotný proces přizpůsobování se nazývá adaptivním procesem.

Obecná teorie systémů a kybernetika (Wiener, Neumann):
dosáhnout cíle nebo udržet požadované chování systému v neurčitých podmínkách

Využití ve vodním hospodářství

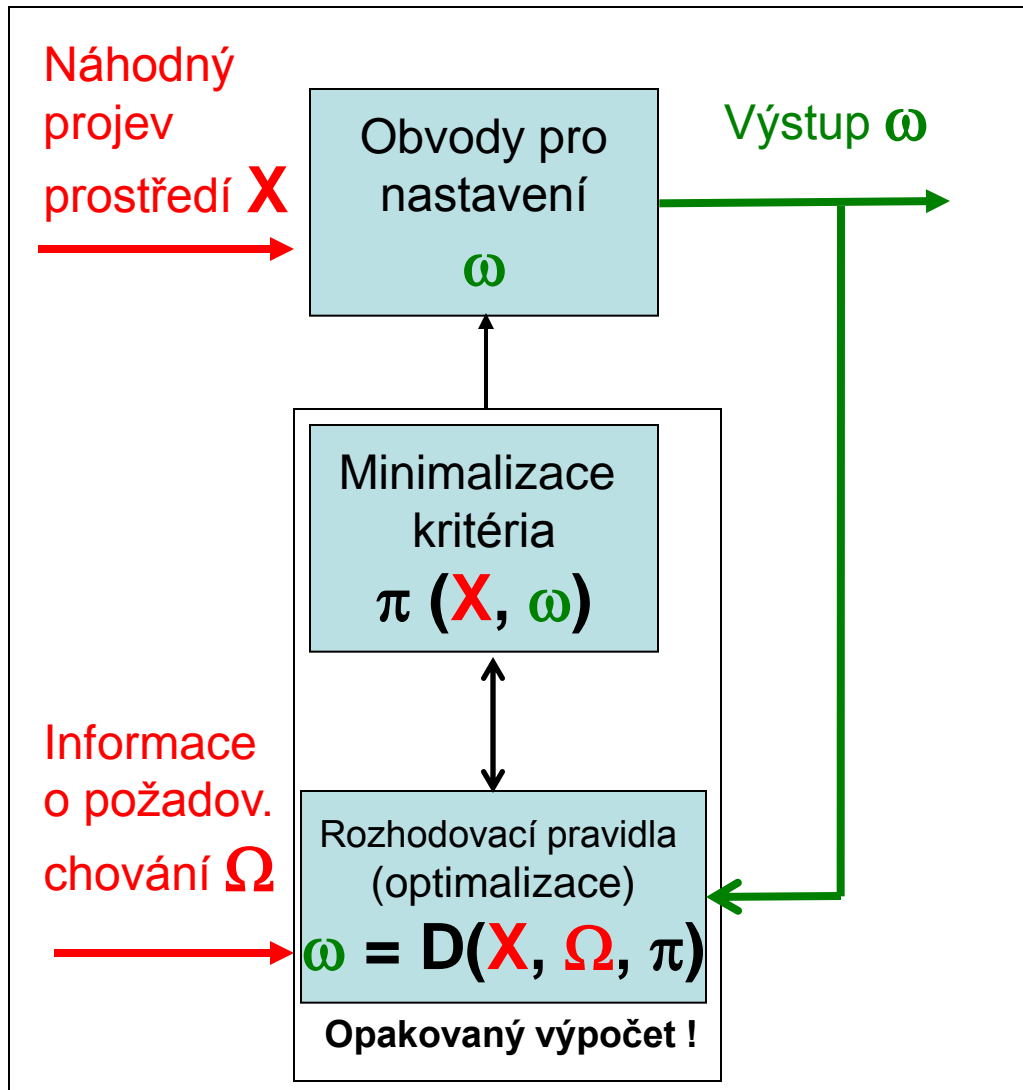
- konstrukce modelů pro operativní řízení odtoku vody z povodí (zásobní funkce, ochranná funkce)

⇒ omezení intuitivního rozhodování při řízení systémů

⇒ objektivizace a stabilizace rozhodovacího procesu v podmínkách neurčitosti

Adaptivita – účinný prostředek proti vlivu neurčitosti

Formalizace adaptivního systému



Vstup

- projev prostředí X
- požadované chování Ω

Symbolický zápis pětici:

$$AS = [X, \Omega, \omega, D, \pi]$$

V praxi často
intuitivní využívání

Učící se systémy

Učící se systémy

Výzkum živých organismů prokázal jejich další schopnost, a to **schopnost učení**.

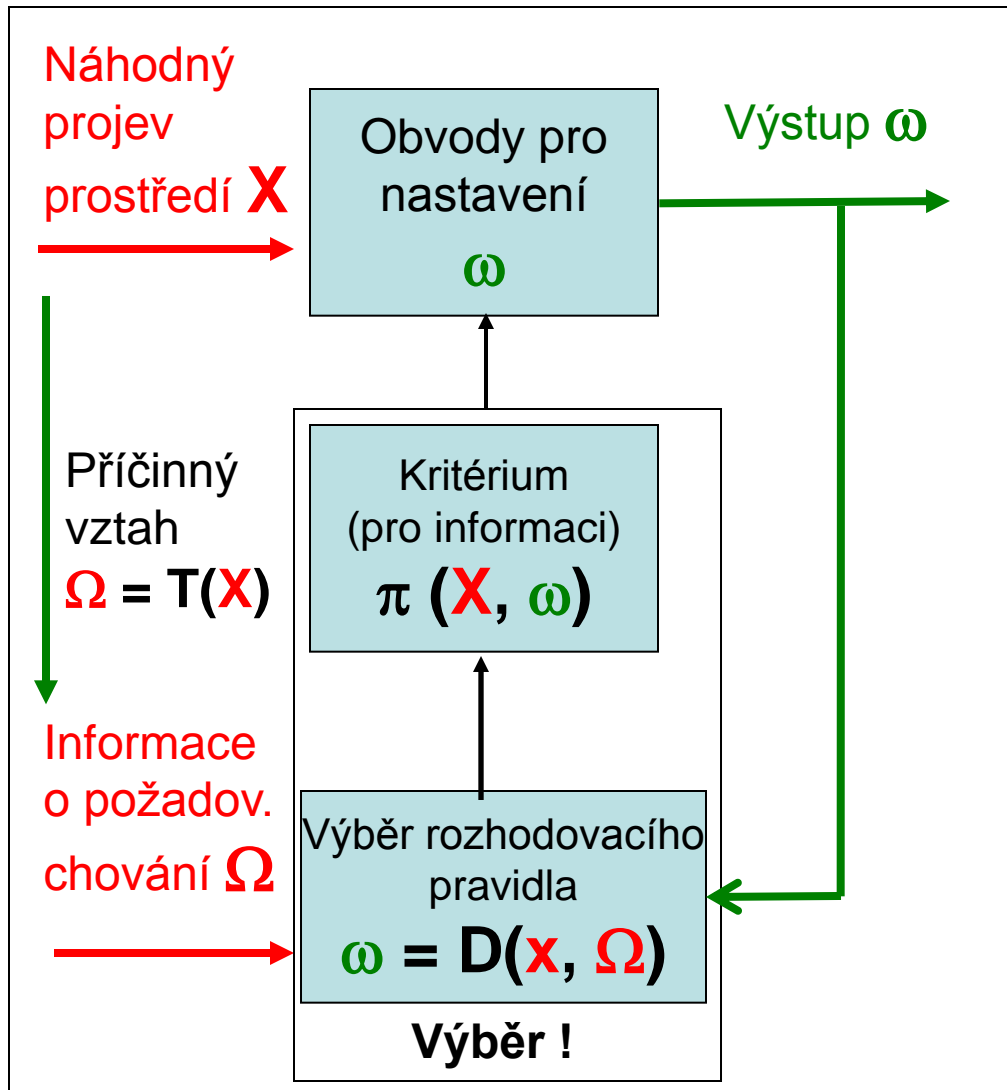
Při mnohanásobném opakování adaptace na nějakou změnu prostředí dokáží organismy v průběhu dlouhého vývoje postupně zmenšovat ztráty vynaložené na adaptaci. Opakování je zdrojem zkušeností, které si organizmus zapamatuje, zhodnocuje a učí se. Tím se snáze přizpůsobuje změněným podmínkám – učí se.

Rozdíl oproti adaptivnímu systému

- **prostý adaptivní systém** neustále opakuje adaptaci (i při témže projevu prostředí bez ohledu na předchozí rozhodnutí)
- **učící se systém** vyhledává v minulosti všechny situace uskutečněné adaptací, získané zkušenosti zhodnocuje a volí takový parametr Q_n , který vede k minimalizaci ztráty Z .

Učící se systém – speciální případ adaptivního systému !

Formalizace funkce naučeného systému



Vstup

- projev prostředí X
- požadované chování Ω

Symbolický zápis šestici:

$$AS = [X, \Omega, \omega, D, T, \pi]$$

Vyžaduje

v předstihu zpracovat
možná chování systému
pomocí využití adaptivity

Genetické algoritmy

Genetické algoritmy (GA)

- **Prohledávací metoda** založená na principu přírodního výběru a genetiky (Holland, Goldberger)
- V každé buňce téhož jedince stejná soustava **chromozonů** (řetězce DNA – slouží k ukládání informací o jedinci)
- Chromozon se skládá z **genů** – části DNA (v každém genu zvláštní rys jedince)

Princip GA jednoduchý - spočívá v **kopírování a přesouvání** bloků bitů (genů).

Lze nasadit na řešení problémů, u nichž lze nějakým způsobem stanovit kvalitu jedince – **fitness hodnota** – kritérium π .

Prostor všech možných hodnot řešení – prohledávaný prostor.

Hledaným řešením je takové řešení (poloha bodu v prostoru), pro které fitness hodnota (kritérium) dosáhne **maximální, resp. minimální** hodnoty

GA

Jedinec (jeden chromozom), **populace**, **generace**

- **Reprodukce** – z počáteční populace jedinců (rodičů) pomocí **křížení a mutace** vzniká další generace jedinců. Výběr rodičů – **selekce**. Geny rodičů určují chromozom nového jedince (poloha bodu v prohledávaném prostoru).

Operátory GA

- **Binární kódování chromozomů**

Chromozom A 1011001011001101110

Chromozom B 1111110000110100111

Kódování pomocí hodnot

Chromozom A 1.54 2.47 5.18 2.36 8.48 3.14 5.67

Chromozom B 1.64 2.41 5.49 2.11 8.01 3.95 5.13

$$r = a + I(B) \cdot \frac{(b-a)}{2^n}$$

Stromové kódování - NS

- **Křížení**

Potomek 1 1011001011110100111

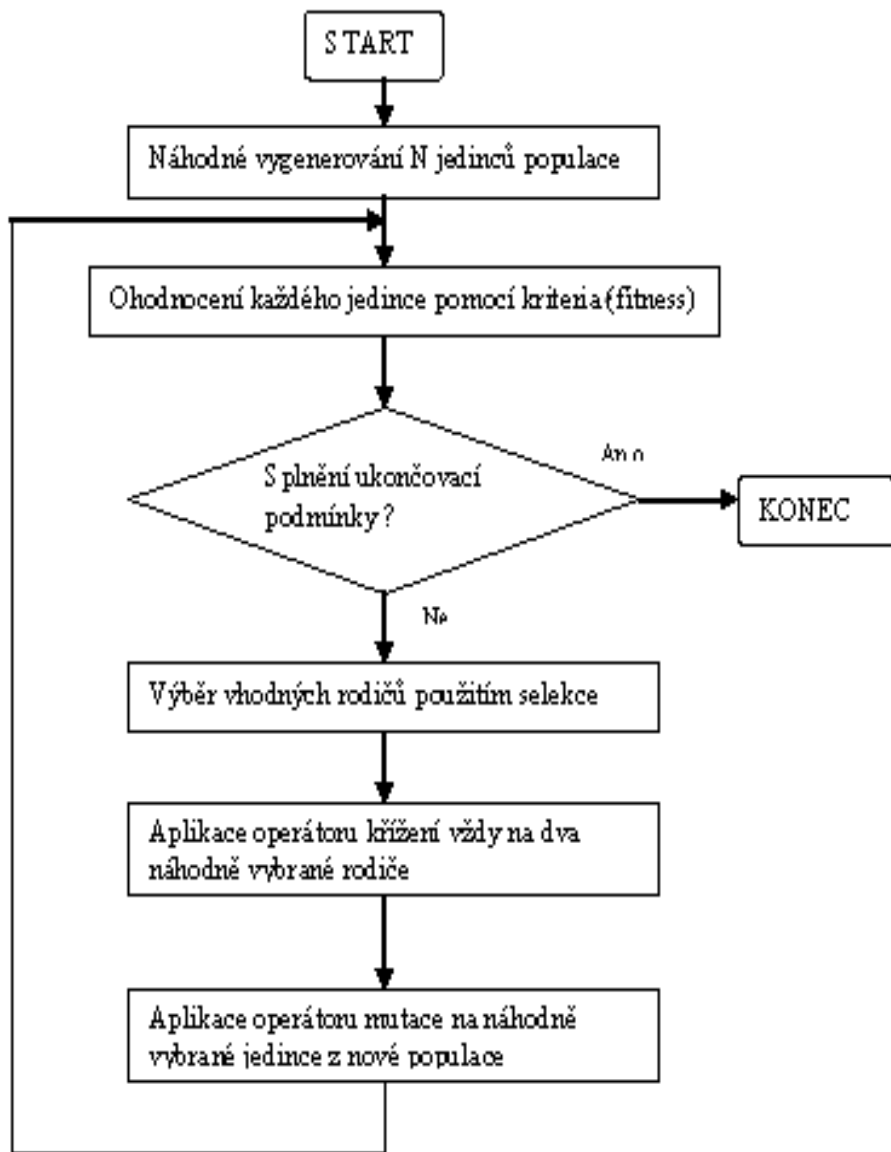
Potomek 2 1111110000001101110

- **Mutace** (pouze určité procento jedinců)

Mut. pot. 1 1011001111110100111

- **Elitismus**

GA - shrnutí



- **Evoluční řešení**
- **Jedinec (chromozom, kritérium = fitness), populace, generace**
- **Reprodukce (selekce, křížení, mutace, elitismus)**
- **Nová populace – naděje, že v ní z hlediska kritéria kvalitnější jedinci**
- **Prohledávaný prostor = prostor všech možných řešení**
- **Každý bod prostoru – jedinec ohodnocený kritériem**
- **hledáním extrému daného kritéria v prostoru**
- **Základní znaky – náhodnostní algoritmy, paralelismus, méně náchylné k uváznutí v pasti lokálního minima**

Využití

- **Kalibrace modelů**
- **Nelineární optimalizace v řídicích algoritmech**
- **Trénování umělých neuronových sítí**


Neuronové sítě

Neuronové sítě (NS)

Černá skříňka


Vstupní prostor

Výstupní prostor



NS

Biologický
neuron



Umělý
neuron

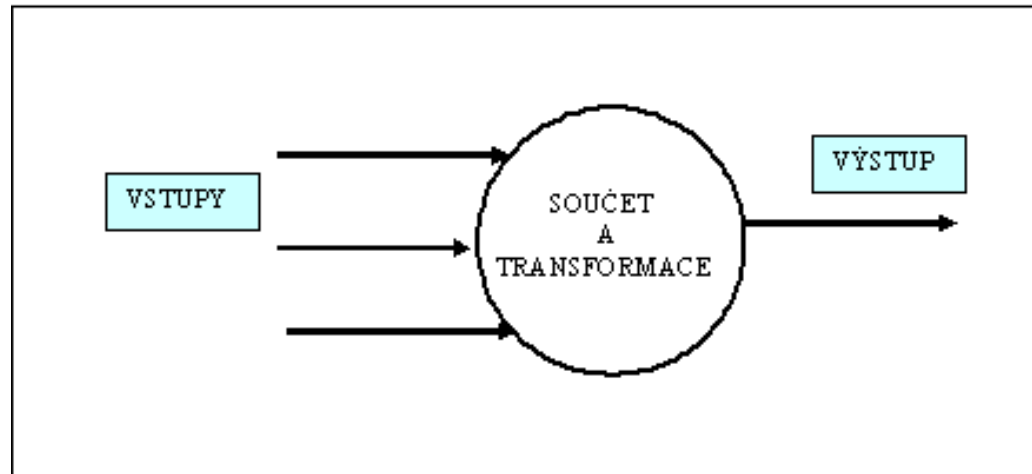
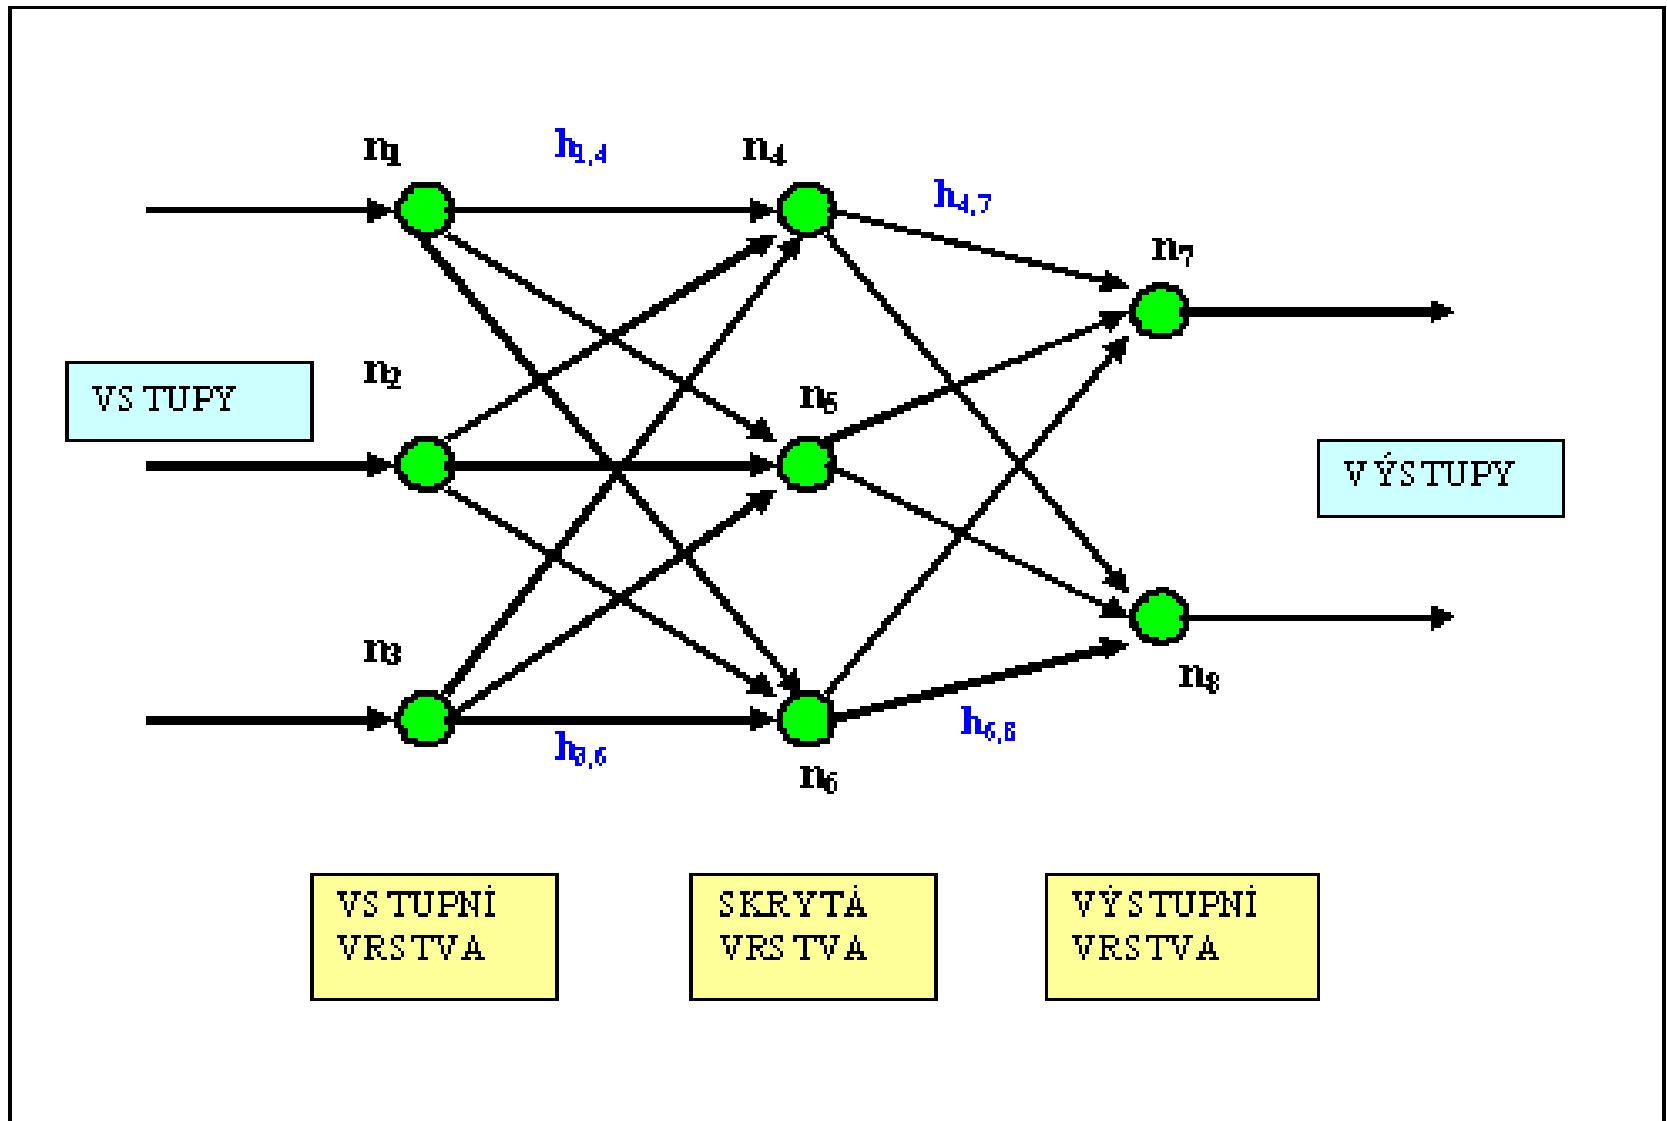
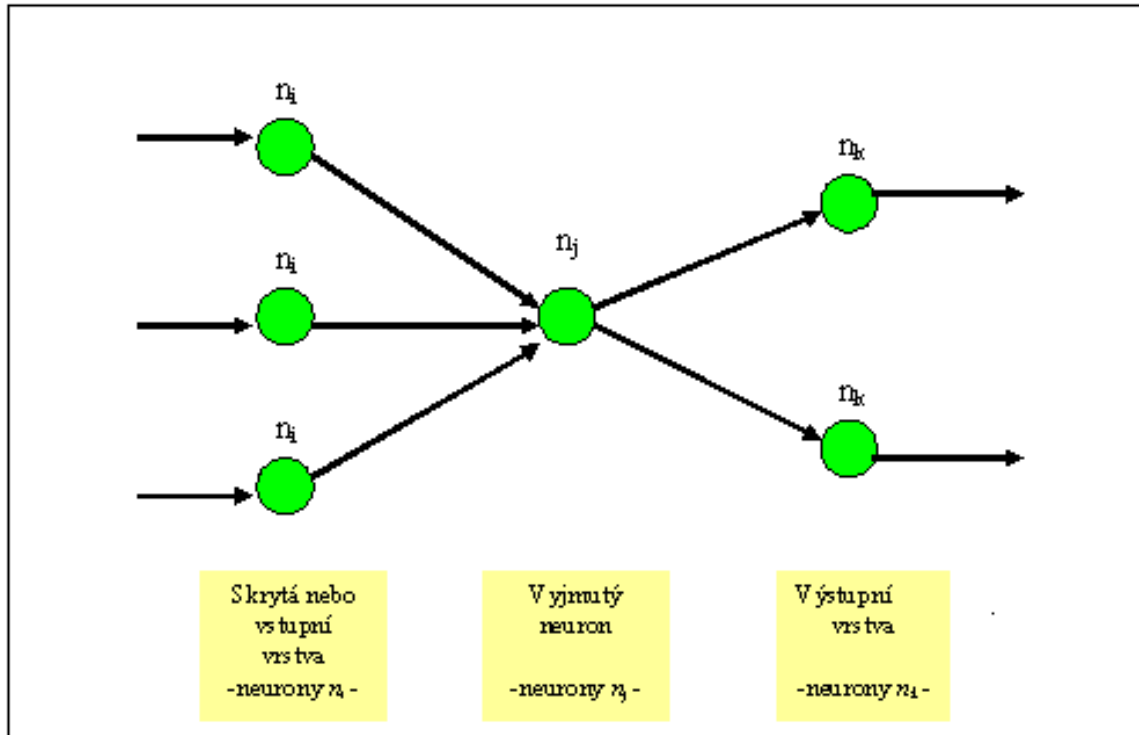


Schéma NS – graf $G(N,h)$



Neuron n_j vyjmutý ze skryté vrstvy



Aktivační funkce neuronu n_j

$$A_j = \sum_{i=u}^v W_{i,j} \cdot O_{i,j} - \theta_j$$

Vzplanutí neuronu n_j

$$\sum_{i=u}^v W_{i,j} \cdot O_{i,j} > \theta_j$$

Výstup z neuronu n_j


$$O_j = TF_j \cdot \left(\sum_{i=u}^v W_{i,j} \cdot O_{i,j} - \theta_j \right)$$

Lineární neuronová síť

$$O_j = A_j = \sum_{i=u}^v W_{i,j} \cdot O_{i,j} - \theta_j$$


Přenosové funkce TF(.)

- Sigmoida




$$O_j = \frac{1}{1 + \exp[-\beta \cdot (\sum_i W_{i,j} \cdot O_{i,j} - \theta_j)]}$$

- Skoková



- Lineární
prahová



- Gaussova


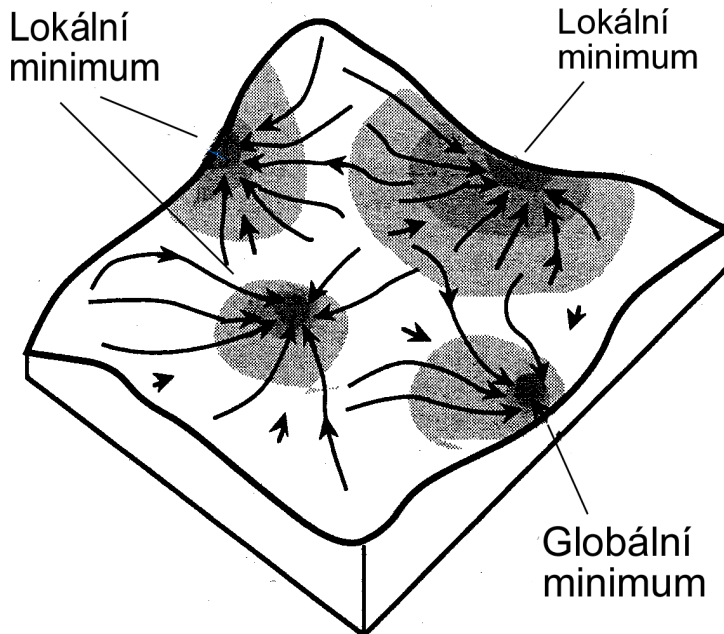


Schéma tréninkové matice

	↓	↓	↓	↓	↑	↑
i	X1	X2	X3	X4	Y1	Y2
1	0.4	12.7	5.1	26.5	6.8	0.3
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
.
.
<i>n</i>	0.3	8.5	3.7	18.9	5.1	0.4




Metody trénování NS


- Metoda zpětného šíření
- Genetické algoritmy
- Mřížková metoda
- Gradientní metody

BrainMaker + GTO - křížení


RODIČ 1



RODIČ 2




POTOMEK




BrainMaker + GTO - mutace

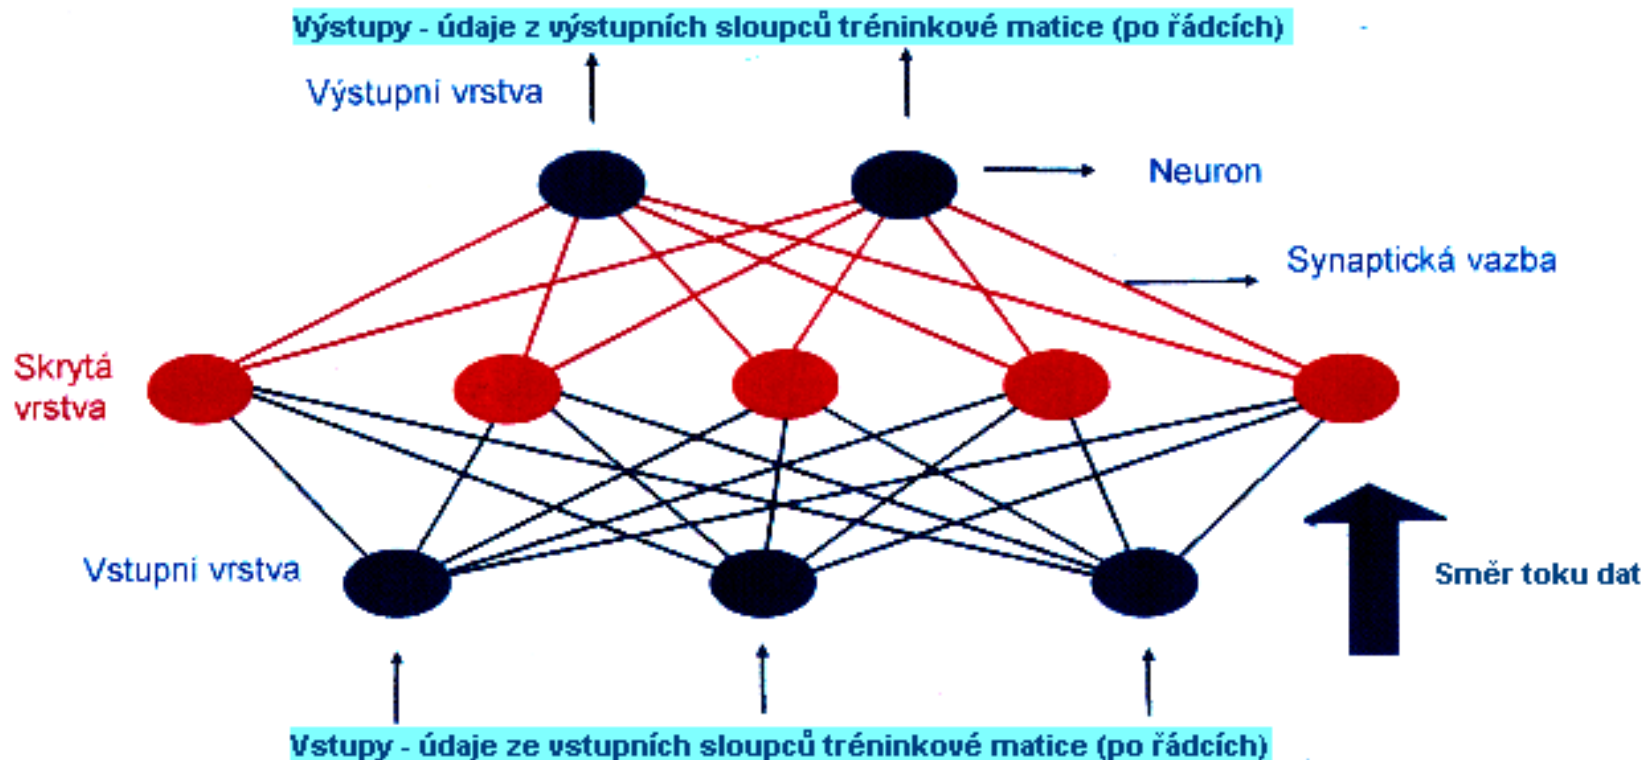
RODIČ



POTOMEK



Neuronové sítě - shrnutí



Funkce neuronu ve skryté vrstvě

Výstup vstupuje do každého neuronu ve výstupní vrstvě

- vynásobte každý vstup váhou spojnice
- sečtěte všechny tyto výsledky
- dosadte součet do přechodové funkce F ("signoida")
- zašlete výstup z každé F do každého neuronu v horní vrstvě

Vstupy z dolní vrstvy neuronů

- Každá spojnice má svou vlastní váhu
- Váhy se postupně mění během trénování množiny

Simulátory NS

- **BrainMaker Professional +GTO** (California Scientific Software)
- **ARTINT** (Mentar +EGU)
- **MATLAB + Neural Networks Toolbox**
- **STATISTICA**
- **WinNN**
- **Neural Connection**
- **Neurex**

NS - topologie

- Které veličiny vstupní a které výstupní (počet vstupních a výstupních neuronů) – dáno charakterem řešené úlohy
- Počet vrstev skrytých neuronů a počet neuronů v nich (Kosko – 1 skrytá vrstva a v ní $2m+1$ neuronů = univerzální aproximátor)
- Počet parametrů (vah) větší než počet vzorů (Kůrková), přetrénování (overfitting) – zapamatování vzorů, ztráta generalizační schopnosti (převážená síť)
- Čím méně vzorů v porovnání s počtem neuronů máme, tím větší pravděpodobnost, že síť natrénujeme, ale ne správně. Narůstá pravděpodobnost libovolného vztahu mezi vstupy a výstupy
- Lawrencová
$$TV > \frac{SN}{PT} \cdot VN$$

Počet tréninkových vzorů (TV) ve vztahu k počtu skrytých neuronů (SN), povolené toleranci (PT) a počtu vstupních neuronů (VN)

- Praxe: $TV > SN \cdot (1/PT)$

NS – topologie – pokr.1

- Jaký je nejlepší počet skrytých neuronů? Existují jen doporučení!!
- Kolik vrstev skrytých neuronů? Existují jen doporučení!! Více vrstev prodlužuje výrazně dobu trénování. Pokud nejde vícevrstvá síť natrénovat => odebrat vrstvu a znovu opakovat trénování
- Past lokálního minima – přidání náhodného šumu po natrénování a pokračování v tréninku (rozkmítání)
- Přidání náhodného šumu zvláště když malý počet vzorů
- Přidání náhodného šumu zvláště když mnoho nul ve vzorech
- Doplnování nových vzorů k již natrénované síti a dotrénování – jde pouze několikrát, pak trénink kompletně znovu
- Zpočátku jde síť dobře trénovat a pak se trénink zpomalí a skoro zastaví – tréninková matice obsahuje špatné vzory (lze připustit určité procento špatných vzorů)
- Někdy vyřeší problém přidání dalších vzorů ty podpoří „zdánlivě špatné vzory“

NS – topologie – pokr.2

- Špatné vzory umožňují vyloučit analyzátoři tréninkové matice
- Dynamické neuronové sítě (Dynamic Node Creation) – začnou trénink s malou sítí a pokud nejde natrénovat, postupně přidávají do skrytých vrstev neurony a skryté vrstvy. Vždy začínají trénink znovu.
- Funguje i opačný postup – velká síť má malé generalizační schopnosti
- Jde dělat manuálně – po natrénování sledovat výstupy z neuronů (příliš velké nebo malé, dva stejné) => neuron lze vyjmout
- Skeletonizace (Mozer, Smolensky) algoritmus pro posuzování vlivu neuronu na funkci dalších neuronů
- Rychlost učení určuje velikost oprav neznámých veličin v procesu učení (váhy, prahy, strmosti, atd.)
- Vyhlazovací faktor určuje míru vlivu, se kterým jsou uvažovány minulé korekce opravovaných veličin, a míru vlivu, se kterým jsou uvažovány korekce nově vypočtené (konjugované gradienty)

NS – topologie – pokr.3

- Rekurentní neuronové sítě se snaží zdokonalit proces učení zavedením spojů mezi neurony jednotlivých neuronových vrstev. Systém má zabránit tomu, toto doplnění má zabránit tomu, aby dva neurony z téže vrstvy reagovaly na vstupní data totožným způsobem
- Rekurentní neurony vznikly jako pokus obohatit neuronové sítě o časový rozměr. Neuronové sítě s rekurentními neurony se hodí pro zpracovávání dat, která tvoří časové řady. Každý neuron ve skryté vrstvě má svůj vlastní rekurentní neuron, který zpracovává svůj předešlý výstup
- Optimalizace topologie a postupu trénování neuronové sítě pomocí mřížkové (grid) metody
- Kompetiční model s Kohonenovou mapou tedy provádí *shlukovou analýzu tréninkové množiny*, tj. určení počtu shluků vstupů tréninkové množiny a jejich rozmístění ve vstupním prostoru. Model je možno použít jako *reduktoru mohutnosti tréninkové matice*

NS – standardizace dat

- Standardizací vstupních dat rozumíme transformaci, která tato data převede na požadované intervaly
- Standardizaci vstupních nebo výstupních dat. V zásadě může být tato transformace *nelineární* nebo *lineární* (výstup – TA(.) sigmoida)
- Transformace vstupů do menších hodnot (větší citlivost sigmoidy) a nejlépe symetricky kolem nuly. Velikost intervalu, na který transformujeme, určuje význam příslušného vstupu. Lze cíleně využít.
- Nejčastěji transformujeme vstupní veličinu x z $N(\mu_x, \sigma_x)$ na x^t z $N(0, 1)$

$$x^t = \frac{x - \mu_x}{\sigma_x}$$

- Lze využít i lineární transformaci výstupu z O_k na O_k^t

$$O_k^t = \frac{O_k - O_{\min}}{O_{\max} - O_{\min}},$$

NS a regresní rovnice

Částečná analogie mezi regresními rovnicemi a neuronovými sítěmi

- **Vícerozměrná lineární regrese**

$$Y = a_1 \cdot X_1 + a_2 \cdot X_2 + a_3 \cdot X_3 + \dots + a_p \cdot X_p,$$

- **Jednosměrná lineární neuronová síť** s jedinou vrstvou vstupních neuronů, jediným výstupním neuronem a s nulovým prahem u všech neuronů

$$O_k = W_{1k} \cdot O_{1k} + W_{2k} \cdot O_{2k} + W_{3k} \cdot O_{3k} + \dots + W_{pk} \cdot O_{pk},$$

- **Sarle 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"*

NS a RR – pokr.

Výhody NS

- Neuronové sítě nevyžadují volbu regresní závislosti (tvar regresní rovnice)
- Učení (trénink) neuronové sítě je analogickým termínem pro kalibraci regresního modelu
- Neuronové sítě mohou obsahovat více výstupů

Závěr

- Pro jednoduché úlohy se lépe hodí použít klasické regresní rovnice. Technika kalibrace těchto modelů je značně propracovaná
- Pro složitější úlohy z oblasti vícerozměrné nelineární regrese se však jeví jako vhodnější použít neuronové sítě, zejména pokud požadujeme souběžně více výstupů

NS - využití

- Neuronové sítě jsou vynikajícím prostředkem pro rozpoznávání závislostí mezi vstupními a výstupními údaji (konstrukci varovných systémů před povodňovými průtoky v ohrožených lokalitách)
- Neuronové sítě nevynikají přesností
- 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 probíhá za značných podmínek neurčitosti
- Pokud není možno popsat vztah mezi soubory dat exaktním vztahem, ale pokud je známo, které veličiny jsou vstupní a mají vliv na veličiny výstupní, neuronové sítě mohou nalézt požadovaný vztah. Ať už je absence exaktního vztahu dána jeho značnou složitostí nebo prostě tím, že není znám
- Výhodou neuronových sítí rovněž je, že pokud se proces, který řídíme, resp. analyzujeme a vyhodnocujeme poněkud změní, je postačující doplnit nové tréninkové vzory do tréninkové matice a provést přetrénování neuronové sítě (snadnější než nový vzorec)