

Učení, rozhodovací stromy, neuronové sítě

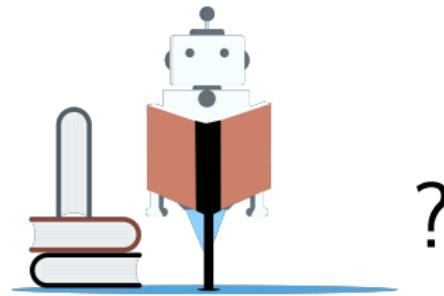
Aleš Horák

E-mail: hales@fi.muni.cz
<http://nlp.fi.muni.cz/uui/>

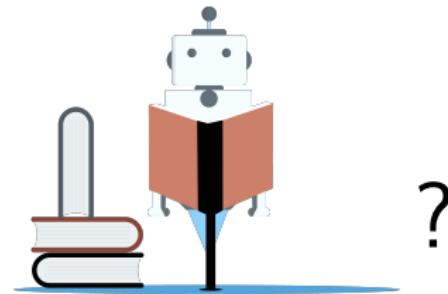
Obsah:

- Učení
- Rozhodovací stromy
- Neuronové sítě

Strojové učení



Strojové učení



sli.do/uui [SliDo](#)

Induktivní učení

známé taky jako **věda** ☺

nejjednodušší forma – učení funkce z příkladů (agent je **tabula rasa**)

f je cílová funkce

každý **příklad** je dvojice $x, f(x)$ např.

O	O	x
	x	
x		

, +1

úkol **indukce**:

najdi **hypotézu h**

takovou, že $h \approx f$

pomocí sady **trénovacích příkladů**

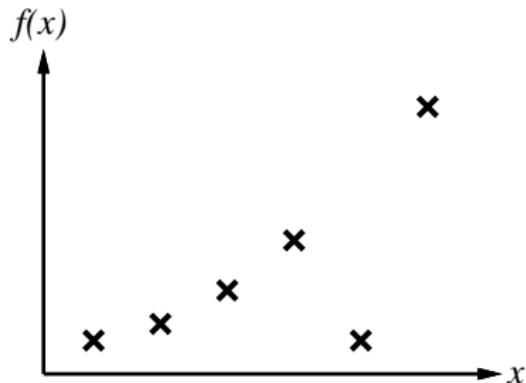
Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

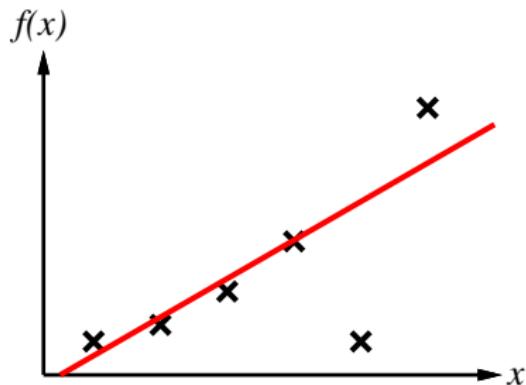
např. hledání křivky:



Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

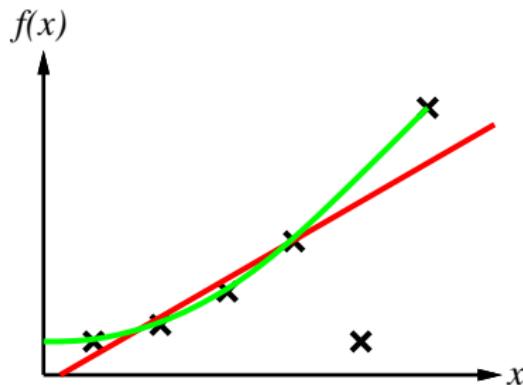
např. hledání křivky:



Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

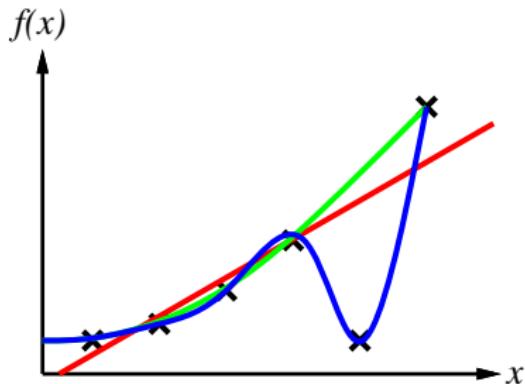
např. hledání křivky:



Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

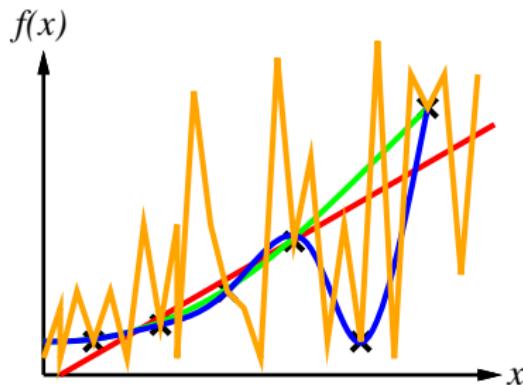
např. hledání křivky:



Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

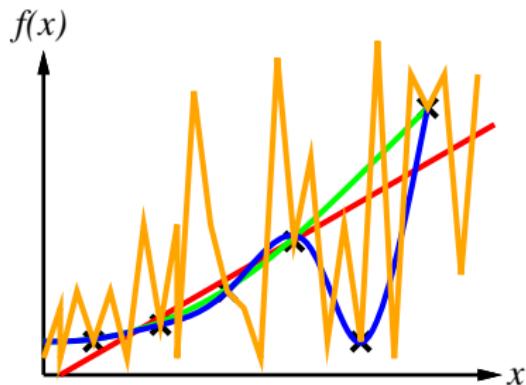
např. hledání křivky:



Metoda induktivního učení

zkonstruuji/uprav h , aby souhlasila s f na trénovacích příkladech
 h je konzistentní \Leftrightarrow souhlasí s f na všech příkladech

např. hledání křivky:



pravidlo **Ockhamovy břity** – maximalizovat kombinaci konzistence a jednoduchosti (*nejjednodušší ze správných je nejlepší*)

Metoda induktivního učení pokrač.

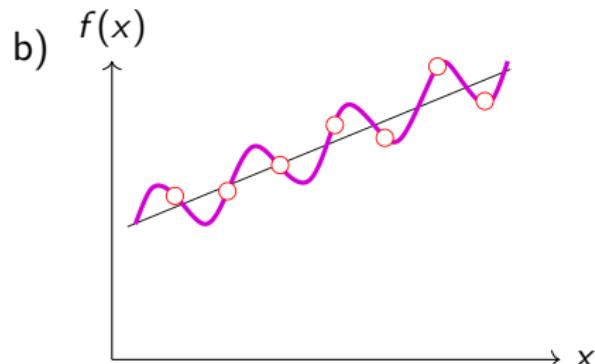
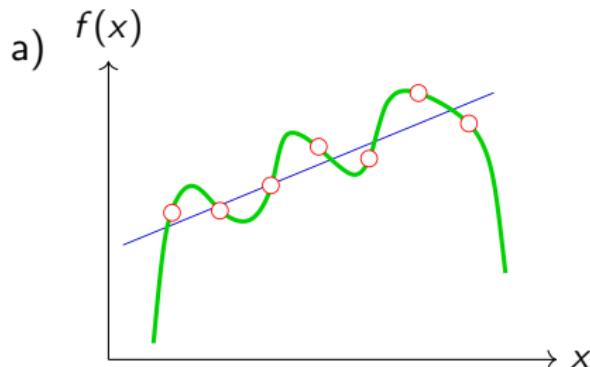
hodně záleží na **prostoru hypotéz**, jsou na něj protichůdné požadavky:

- pokrýt co **největší množství** hledaných funkcí
- udržet **nízkou výpočetní složitost** hypotézy

Metoda induktivního učení pokrač.

hodně záleží na **prostoru hypotéz**, jsou na něj protichůdné požadavky:

- pokrýt co **největší množství** hledaných funkcí
- udržet **nízkou výpočetní složitost** hypotézy



- stejná sada 7 bodů
- nejmenší konzistentní polynom – polynom 6-tého stupně (7 parametrů)
- může být výhodnější použít nekonzistentní **přibližnou** lineární funkci
- přitom existuje konzistentní funkce $ax + by + c \sin x$

Hodnocení úspěšnosti učícího algoritmu

jak můžeme zjistit, zda $h \approx f$?

Hodnocení úspěšnosti učícího algoritmu

jak můžeme zjistit, zda $h \approx f$? 

dopředu – použít věty Teorie komputačního učení
po naučení – kontrolou na jiné trénovací sadě

Hodnocení úspěšnosti učícího algoritmu

jak můžeme zjistit, zda $h \approx f$? <

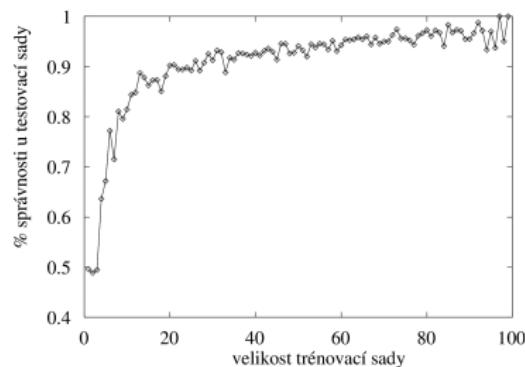
- dopředu – použít věty Teorie komputačního učení
- po naučení – kontrolou na jiné trénovací sadě

používaná **metodologie** (cross validation):

1. vezmeme velkou množinu příkladů
2. rozdělíme ji na 2 množiny – **trénovací** a **testovací**
3. aplikujeme učící algoritmus na **trénovací** sadu, získáme hypotézu h
4. změříme procento příkladů v **testovací** sadě, které jsou správně klasifikované hypotézou h
5. opakujeme kroky 2–4 pro různé velikosti trénovacích sad a pro náhodně vybrané trénovací sady

SliDo

křivka učení – závislost úspěšnosti na velikosti trénovací sady



Hodnocení úspěšnosti učícího algoritmu – pokrač.

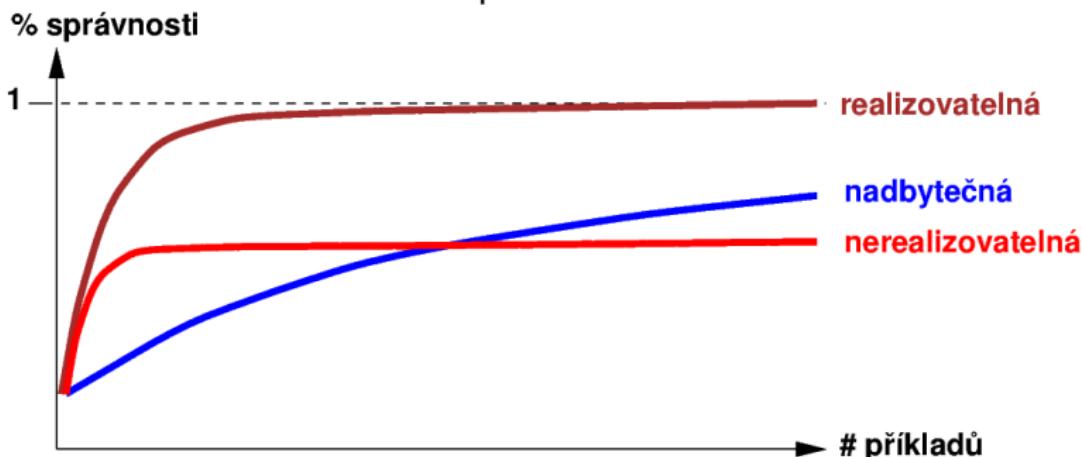
tvar křivky učení závisí na

- je hledaná funkce

realizovatelná \times nerealizovatelná
funkce může být nerealizovatelná kvůli

- chybějícím atributům
- omezenému prostoru hypotéz

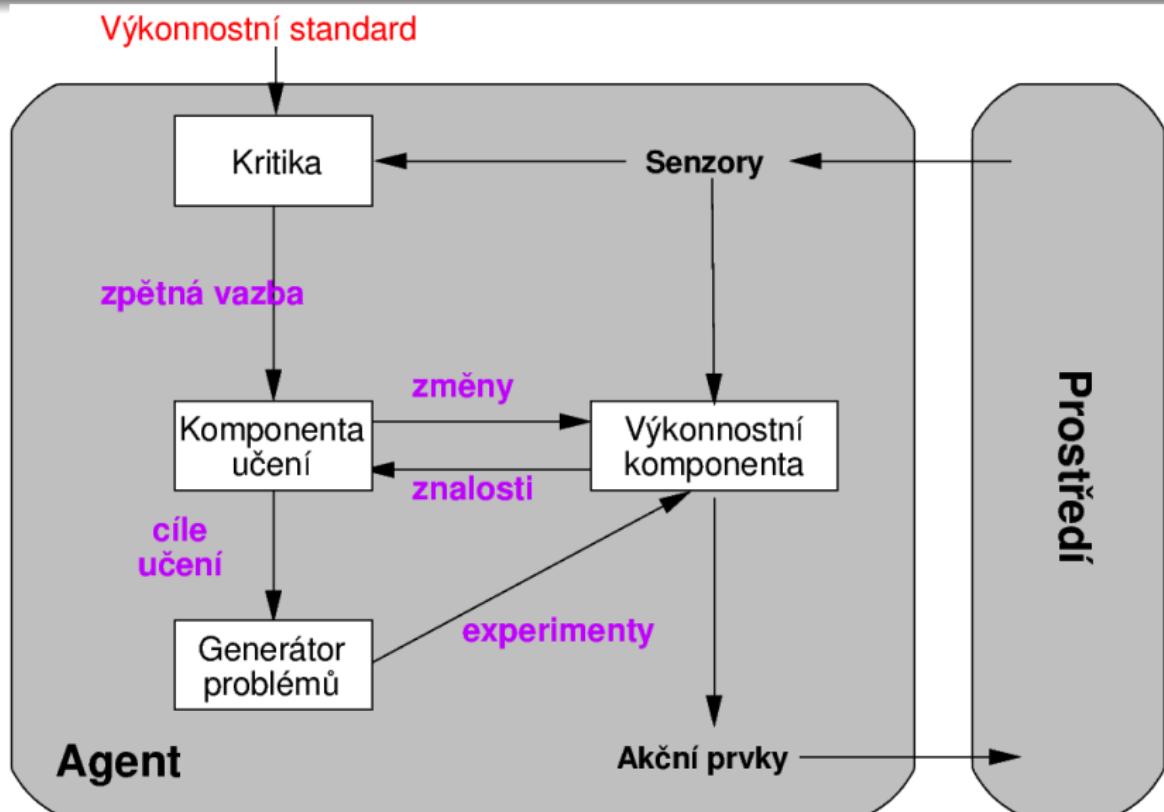
- naopak nadbytečné expresivitě
např. množství nerelevantních atributů



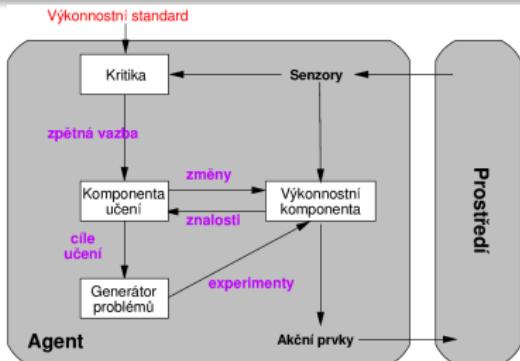
Učící se agent

- **učení** agenta – využití jeho vjemů z prostředí nejen pro vyvození další akce
- učení **modifikuje rozhodovací systém** agenta pro zlepšení jeho výkonnosti
- učení je klíčové pro **neznámé prostředí** (kde návrhář není vševedoucí)
- učení je také někdy vhodné jako **metoda konstrukce** systému – vystavit agenta realitě místo přepisování reality do pevných pravidel

Učící se agent



Učící se agent



příklad automatického taxi:

- **Výkonnostní komponenta** – obsahuje znalosti a postupy pro výběr akcí pro vlastní řízení auta
- **Kritika** – sleduje reakce okolí na akce taxi. Např. při rychlém přejetí 3 podélných pruhů zaznamená a předá pohoršující reakce dalších řidičů
- **Komponenta učení** – z hlášení Kritiky vyvodí nové pravidlo, že takové přejíždění je nevhodné, a modifikuje odpovídajícím způsobem Výkonnostní komponentu
- **Generátor problémů** – zjišťuje, které oblasti by mohly potřebovat vylepšení a navrhuje experimenty, jako je třeba brzdění na různých typech vozovky

Komponenta učení

návrh komponenty učení závisí na několika atributech:

- jaký typ výkonnostní komponenty je použit
- která funkční část výkonnostní komponenty má být učena
- jak je tato funkční část reprezentována
- jaká zpětná vazba je k dispozici

výkonnostní komponenta	funkční část	reprezentace	zpětná vazba
Alfa-beta prohledávání	ohodnocovací funkce	vážená lineární funkce	výhra/prohra
Logický agent	určení akce	axiomy <i>Result</i>	výsledné skóre
Reflexní agent	váhy perceptronu	neuronová síť	správná/špatná akce

Komponenta učení

návrh komponenty učení závisí na několika atributech:

- jaký typ výkonnostní komponenty je použit
- která funkční část výkonnostní komponenty má být učena
- jak je tato funkční část reprezentována
- jaká zpětná vazba je k dispozici

výkonnostní komponenta	funkční část	reprezentace	zpětná vazba
Alfa-beta prohledávání	ohodnocovací funkce	vážená lineární funkce	výhra/prohra
Logický agent	určení akce	axiomy <i>Result</i>	výsledné skóre
Reflexní agent	váhy perceptronu	neuronová síť	správná/špatná akce

učení s dohledem (*supervised learning*) × bez dohledu (*unsupervised learning*)

- s dohledem – učení funkce z příkladů vstupů a výstupů
- bez dohledu – učení vzorů na vstupu vzhledem k reakcím prostředí
- zpětnovazební (*reinforcement learning*) – agent se učí podle odměn/pokut

Učení – shrnutí

- **učení** je potřebné pro **neznámé prostředí** (a líné analytiky ☺)
- **učící se agent** – výkonnostní komponenta a komponenta učení
- **metoda** učení závisí na **typu výkonnostní komponenty**, dostupné **zpětné vazbě**, **typu** a **reprezentaci** části, která se má učením zlepšit
- **u učení s dohledem** – cíl je najít nejjednodušší hypotézu přibližně konzistentní s trénovacími příklady
- **kvalita učení** – přesnost odhadu změřená na testovací sadě

Obsah

1 Učení

- Induktivní učení
- Hodnocení úspěšnosti učícího algoritmu
- Učící se agent
- Komponenta učení
- Učení – shrnutí

2 Rozhodovací stromy

- Atributová reprezentace příkladů
- Rozhodovací stromy
- Učení formou rozhodovacích stromů

3 Neuronové sítě

- Počítačový model neuronu
- Struktury neuronových sítí

Atributová reprezentace příkladů

příklady popsané výčtem hodnot atributů (libovolných hodnot)

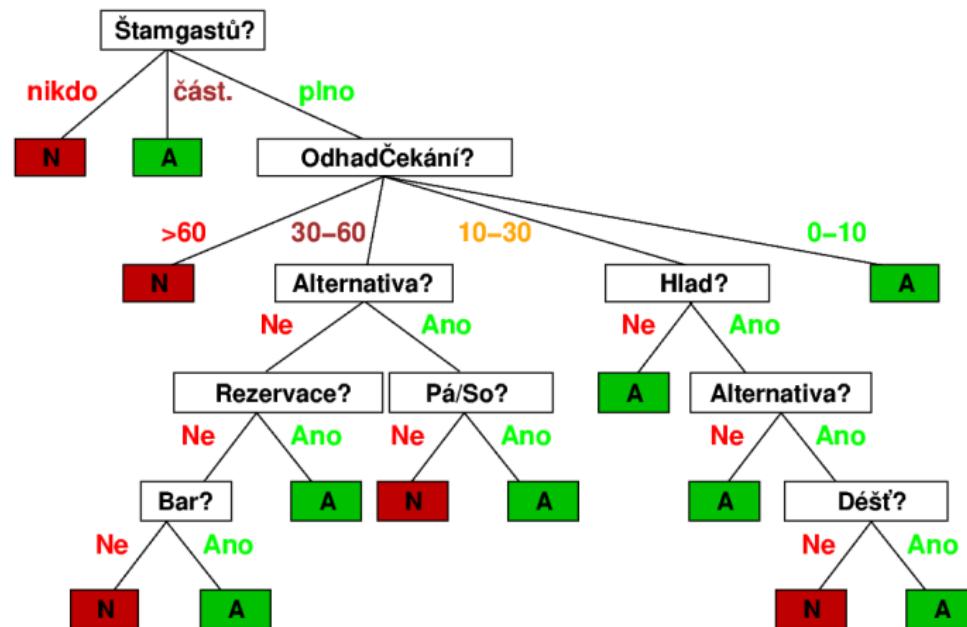
např. rozhodování, zda **počkat** na uvolnění stolu v restauraci:

Příklad	Atributy										počkat?
	Alt	Bar	Pá/So	Hlad	Štam	Cen	Děšť'	Rez	Typ	ČekD	
X ₁	A	N	N	A	část.	\$\$\$	N	A	mexická	0–10	A
X ₂	A	N	N	A	plno	\$	N	N	asijská	30–60	N
X ₃	N	A	N	N	část.	\$	N	N	bufet	0–10	A
X ₄	A	N	A	A	plno	\$	N	N	asijská	10–30	A
X ₅	A	N	A	N	plno	\$\$\$	N	A	mexická	>60	N
X ₆	N	A	N	A	část.	\$\$	A	A	pizzerie	0–10	A
X ₇	N	A	N	N	nikdo	\$	A	N	bufet	0–10	N
X ₈	N	N	N	A	část.	\$\$	A	A	asijská	0–10	A
X ₉	N	A	A	N	plno	\$	A	N	bufet	>60	N
X ₁₀	A	A	A	A	plno	\$\$\$	N	A	pizzerie	10–30	N
X ₁₁	N	N	N	N	nikdo	\$	N	N	asijská	0–10	N
X ₁₂	A	A	A	A	plno	\$	N	N	bufet	30–60	A

Ohodnocení tvoří **klasifikaci** příkladů – **pozitivní** (A) a **negativní** (N)

Rozhodovací stromy

jedna z možných reprezentací hypotéz – **rozhodovací strom** pro určení, jestli počkat na stůl:



Vyjadřovací síla rozhodovacích stromů

rozhodovací stromy vyjádří libovolnou Booleovskou funkci vstupních atributů → odpovídá **výrokové logice**

$$\forall s \text{ počkat?}(s) \Leftrightarrow (P_1(s) \vee P_2(s) \vee \dots \vee P_n(s)),$$

$$\text{kde } P_i(s) = (A_1(s) = V_1 \wedge \dots \wedge A_m(s) = V_m)$$

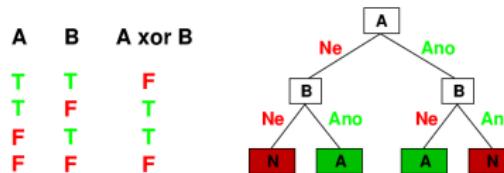
Vyjadřovací síla rozhodovacích stromů

rozhodovací stromy vyjádří libovolnou Booleovskou funkci vstupních atributů → odpovídá **výrokové logice**

$$\forall s \text{ počkat?}(s) \Leftrightarrow (P_1(s) \vee P_2(s) \vee \dots \vee P_n(s)),$$

$$\text{kde } P_i(s) = (A_1(s) = V_1 \wedge \dots \wedge A_m(s) = V_m)$$

pro libovolnou Booleovskou funkci → řádek v pravdivostní tabulce = cesta ve stromu (od kořene k listu)



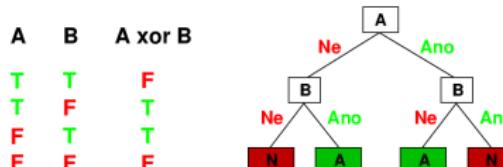
Vyjadřovací síla rozhodovacích stromů

rozhodovací stromy vyjádří libovolnou Booleovskou funkci vstupních atributů → odpovídá **výrokové logice**

$$\forall s \text{ počkat?}(s) \Leftrightarrow (P_1(s) \vee P_2(s) \vee \dots \vee P_n(s)),$$

$$\text{kde } P_i(s) = (A_1(s) = V_1 \wedge \dots \wedge A_m(s) = V_m)$$

pro libovolnou Booleovskou funkci → řádek v pravdivostní tabulce = cesta ve stromu (od kořene k listu)



triviálně

pro libovolnou trénovací sadu *existuje* konzistentní **rozhodovací strom** s jednou cestou k listům pro každý příklad

ale takový strom pravděpodobně nebude generalizovat na nové příklady chceme najít co možná **kompaktní** rozhodovací strom

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

= počet všech Booleovských funkcí nad těmito atributy

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

= počet všech Booleovských funkcí nad těmito atributy

= počet různých pravdivostních tabulek s 2^n řádky

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

= počet všech Booleovských funkcí nad těmito atributy

= počet různých pravdivostních tabulek s 2^n řádky = 2^{2^n}

např. pro 6 atributů existuje 18 446 744 073 709 551 616 různých rozhodovacích stromů

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

= počet všech Booleovských funkcí nad těmito atributy

= počet různých pravdivostních tabulek s 2^n řádky = 2^{2^n}

např. pro 6 atributů existuje 18 446 744 073 709 551 616 různých rozhodovacích stromů

2. když se omezíme pouze na konjunktivní hypotézy ($H\text{lad} \wedge \neg D\text{ěst'}$)

Kolik existuje takových čistě konjunktivních hypotéz?

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

= počet všech Booleovských funkcí nad těmito atributy

= počet různých pravdivostních tabulek s 2^n řádky = 2^{2^n}

např. pro 6 atributů existuje 18 446 744 073 709 551 616 různých rozhodovacích stromů

2. když se omezíme pouze na konjunktivní hypotézy ($Hlad \wedge \neg Děšť$)

Kolik existuje takových čistě konjunktivních hypotéz?

každý atribut může být v pozitivní nebo negativní formě nebo nepoužit

⇒ 3^n různých konjunktivních hypotéz (pro 6 atributů = 729)

Prostor hypotéz

1. vezměme pouze Booleovské atributy, bez dalšího omezení

Kolik existuje různých rozhodovacích stromů s n Booleovskými atributy?

= počet všech Booleovských funkcí nad těmito atributy

= počet různých pravdivostních tabulek s 2^n řádky = 2^{2^n}

např. pro 6 atributů existuje 18 446 744 073 709 551 616 různých rozhodovacích stromů

2. když se omezíme pouze na konjunktivní hypotézy ($Hlad \wedge \neg Děšť$)

Kolik existuje takových čistě konjunktivních hypotéz?

každý atribut může být v pozitivní nebo negativní formě nebo nepoužit

⇒ 3^n různých konjunktivních hypotéz (pro 6 atributů = 729)

prostor hypotéz s větší **expresivitou**

- zvyšuje šance, že najdeme přesné vyjádření cílové funkce
- ALE zvyšuje i počet možných hypotéz, které jsou konzistentní s trénovací množinou

⇒ můžeme získat nižší kvalitu předpovědí (generalizace)

Učení formou rozhodovacích stromů

• triviální konstrukce rozhodovacího stromu

- pro každý příklad v trénovací sadě přidej jednu cestu od kořene k listu
- na stejných příkladech jako v trénovací sadě bude fungovat přesně
- na nových příkladech se bude chovat náhodně – negeneralizuje vzory z příkladů, pouze kopíruje pozorování

Učení formou rozhodovacích stromů

• triviální konstrukce rozhodovacího stromu

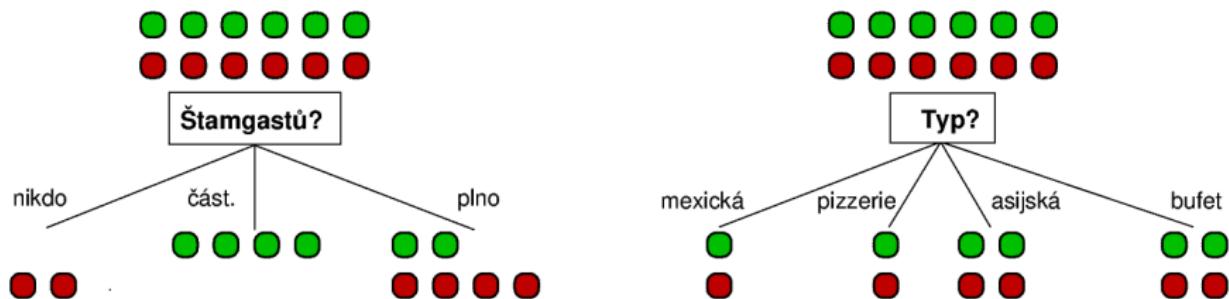
- pro každý příklad v trénovací sadě přidej jednu cestu od kořene k listu
- na stejných příkladech jako v trénovací sadě bude fungovat přesně
- na nových příkladech se bude chovat náhodně – negeneralizuje vzory z příkladů, pouze kopíruje pozorování

• heuristická konstrukce kompaktního stromu

- chceme najít nejmenší rozhodovací strom, který souhlasí s příklady
- přesné nalezení nejmenšího stromu je ovšem příliš složité
 - heuristikou najdeme alespoň dostatečně malý
- hlavní myšlenka – vybíráme atributy pro test v co nejlepším pořadí
- algoritmus IDT, Induction of Decision Trees

Výběr atributu

dobrý atribut \equiv rozdělí příklady na podmnožiny, které jsou (nejlépe) "všechny pozitivní" nebo "všechny negativní"



Štamgastů? je lepší volba atributu \leftarrow dává lepší **informaci** o vlastní **klasifikaci** příkladů

Výběr atributu – míra informace

informace – odpovídá na **otázku**

čím méně dopředu vím o výsledku obsaženém v odpovědi → tím **více** informace je v ní obsaženo

míra: **1 bit** = odpověď na Booleovskou otázku s pravděpodobností odpovědi $\langle P(T) = \frac{1}{2}, P(F) = \frac{1}{2} \rangle$

Výběr atributu – míra informace

informace – odpovídá na **otázku**

čím méně dopředu vím o výsledku obsaženém v odpovědi → tím **více** informace je v ní obsaženo

míra: **1 bit** = odpověď na Booleovskou otázku s pravděpodobností odpovědi $\langle P(T) = \frac{1}{2}, P(F) = \frac{1}{2} \rangle$

n možných odpovědí $\langle P(v_1), \dots, P(v_n) \rangle$ → **míra informace** v odpovědi obsažená

$$I(\langle P(v_1), \dots, P(v_n) \rangle) = \sum_{i=1}^n -P(v_i) \log_2 P(v_i)$$

tato míra se také nazývá **entropie**

Výběr atributu – míra informace

informace – odpovídá na **otázku**

čím méně dopředu vím o výsledku obsaženém v odpovědi → tím **více** informace je v ní obsaženo

míra: **1 bit** = odpověď na Booleovskou otázku s pravděpodobností odpovědi $\langle P(T) = \frac{1}{2}, P(F) = \frac{1}{2} \rangle$

n možných odpovědí $\langle P(v_1), \dots, P(v_n) \rangle$ → **míra informace** v odpovědi obsažená

$$I(\langle P(v_1), \dots, P(v_n) \rangle) = \sum_{i=1}^n -P(v_i) \log_2 P(v_i)$$

tato míra se také nazývá **entropie**

např. pro házení mincí: $I(\langle \frac{1}{2}, \frac{1}{2} \rangle) = -\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{2} \log_2 \frac{1}{2} = \frac{1}{2} + \frac{1}{2} = 1$ bit

pro házení *falešnou* mincí, která dává na 99% vždy jednu stranu mince:

$$I(\langle \frac{1}{100}, \frac{99}{100} \rangle) = -\frac{1}{100} \log_2 \frac{1}{100} - \frac{99}{100} \log_2 \frac{99}{100} = 0.08 \text{ bitů}$$

Použití míry informace pro výběr atributu

předpokládejme, že máme p pozitivních a n negativních příkladů

$\Rightarrow I(\langle \frac{p}{p+n}, \frac{n}{p+n} \rangle)$ bitů je potřeba pro klasifikaci nového příkladu

např. pro X_1, \dots, X_{12} z volby čekání na stůl je $p = n = 6$, takže potřebujeme **1 bit**

Použití míry informace pro výběr atributu

předpokládejme, že máme p pozitivních a n negativních příkladů

$\Rightarrow I(\langle \frac{p}{p+n}, \frac{n}{p+n} \rangle)$ bitů je potřeba pro klasifikaci nového příkladu

např. pro X_1, \dots, X_{12} z volby čekání na stůl je $p = n = 6$, takže potřebujeme **1 bit**

výběr atributu – kolik informace nám dá test na hodnotu atributu A?

Použití míry informace pro výběr atributu

předpokládejme, že máme p pozitivních a n negativních příkladů

$\Rightarrow I(\langle \frac{p}{p+n}, \frac{n}{p+n} \rangle)$ bitů je potřeba pro klasifikaci nového příkladu

např. pro X_1, \dots, X_{12} z volby čekání na stůl je $p = n = 6$, takže potřebujeme **1 bit**

výběr atributu – kolik informace nám dá test na hodnotu atributu A ?

= rozdíl odhadu odpovědi před a po testu atributu

Použití míry informace pro výběr atributu

atribut A rozdělí sadu příkladů E na podmnožiny E_i

(nejlépe tak, že každá potřebuje méně informace)



nechť E_i má p_i pozitivních a n_i negativních příkladů

\Rightarrow je potřeba $I\left(\left\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \right\rangle\right)$ bitů pro klasifikaci nového příkladu

\Rightarrow očekávaný počet bitů celkem je $Remainder(A) = \sum_i \frac{p_i+n_i}{p+n} \cdot I\left(\left\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \right\rangle\right)$

\Rightarrow výsledný **zisk atributu** A je $Gain(A) = I\left(\left\langle \frac{p}{p+n}, \frac{n}{p+n} \right\rangle\right) - Remainder(A)$

Použití míry informace pro výběr atributu

atribut A rozdělí sadu příkladů E na podmnožiny E_i

(nejlépe tak, že každá potřebuje méně informace)



nechť E_i má p_i pozitivních a n_i negativních příkladů

\Rightarrow je potřeba $I\left(\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \rangle\right)$ bitů pro klasifikaci nového příkladu

\Rightarrow očekávaný počet bitů celkem je $Remainder(A) = \sum_i \frac{p_i+n_i}{p+n} \cdot I\left(\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \rangle\right)$

\Rightarrow výsledný **zisk atributu** A je $Gain(A) = I\left(\langle \frac{p}{p+n}, \frac{n}{p+n} \rangle\right) - Remainder(A)$

výběr atributu = nalezení atributu s nejvyšší hodnotou $Gain(A)$

Použití míry informace pro výběr atributu

atribut A rozdělí sadu příkladů E na podmnožiny E_i

(nejlépe tak, že každá potřebuje méně informace)



nechť E_i má p_i pozitivních a n_i negativních příkladů

\Rightarrow je potřeba $I\left(\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \rangle\right)$ bitů pro klasifikaci nového příkladu

\Rightarrow očekávaný počet bitů celkem je $Remainder(A) = \sum_i \frac{p_i+n_i}{p+n} \cdot I\left(\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \rangle\right)$

\Rightarrow výsledný zisk atributu A je $Gain(A) = I\left(\langle \frac{p}{p+n}, \frac{n}{p+n} \rangle\right) - Remainder(A)$

výběr atributu = nalezení atributu s nejvyšší hodnotou $Gain(A)$

$$Gain(\text{Štamgastů?}) \approx 0.541 \text{ bitů}$$

$$Gain(\text{Typ?}) = 0 \text{ bitů}$$

Použití míry informace pro výběr atributu

atribut A rozdělí sadu příkladů E na podmnožiny E_i
 (nejlépe tak, že každá potřebuje méně informace)



nechť E_i má p_i pozitivních a n_i negativních příkladů

\Rightarrow je potřeba $I\left(\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \rangle\right)$ bitů pro klasifikaci nového příkladu

\Rightarrow očekávaný počet bitů celkem je $Remainder(A) = \sum_i \frac{p_i+n_i}{p+n} \cdot I\left(\langle \frac{p_i}{p_i+n_i}, \frac{n_i}{p_i+n_i} \rangle\right)$

\Rightarrow výsledný **zisk atributu** A je $Gain(A) = I\left(\langle \frac{p}{p+n}, \frac{n}{p+n} \rangle\right) - Remainder(A)$

výběr atributu = nalezení atributu s nejvyšší hodnotou $Gain(A)$

$$Gain(\text{Štamgastů?}) \approx 0.541 \text{ bitů} \quad Gain(\text{Typ?}) = 0 \text{ bitů}$$

obecně: E_i (pro $A = v_i$) obsahuje $c_{i,k}$ klasifikací do tříd c_1, \dots, c_k

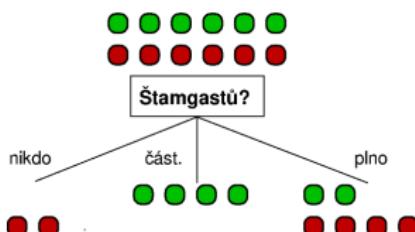
$\Rightarrow Remainder(A) = \sum_i P(v_i) \cdot I\left(\langle P(c_{i,1}), \dots, P(c_{i,k}) \rangle\right)$

$\Rightarrow Gain(A) = I\left(\langle P(v_1), \dots, P(v_n) \rangle\right) - Remainder(A)$

Algoritmus IDT – učení formou rozhodovacích stromů

rekurzivní **tvorba** rozhodovacího stromu (vstup = atributy+příklady):

1. prázdný strom – pokud nejsou další příklady
2. listový uzel – pokud jsou příklady stejného typu 
3. uzel s testem na atribut – pokud existuje nejlepší atribut podle *Gain()*



každý **podstrom** pro podmnožinu příkladů od kroku 1.

4. listový uzel s distribucí typů – jinak



Algoritmus IDT – příklad

```
attributes = { "hlad": ["ano", "ne"],  
              "štam": ["nikdo", "část", "plno"],  
              "cen": ["$", "$$", "$$$"], ... }  
examples = [  
    ("počkat", [  
        ("alt", "ano"), ("bar", "ne"), ("páso", "ne"), ("hlad", "ano"), ("štam", "část"),  
        ("cen", "$$$"), ("déšť", "ne"), ("rez", "ano"), ("typ", "mexická") ]),  
    ("nečekat", [  
        ("alt", "ano"), ("bar", "ne"), ("páso", "ne"), ("hlad", "ano"), ("štam", "plno"),  
        ("cen", "$"), ("déšť", "ne"), ("rez", "ne"), ("typ", "asijská") ]), ... ]
```

Algoritmus IDT – příklad

```

attributes = { "hlad": ["ano", "ne"],
               "štam": ["nikdo", "část", "plno"],
               "cen": ["$", "$$", "$$$"], ... }

examples = [
    ("počkat", [
        ("alt", "ano"), ("bar", "ne"), ("páso", "ne"), ("hlad", "ano"), ("štam", "část"),
        ("cen", "$$$"), ("déšť", "ne"), ("rez", "ano"), ("typ", "mexická") ]),
    ("nečekat", [
        ("alt", "ano"), ("bar", "ne"), ("páso", "ne"), ("hlad", "ano"), ("štam", "plno"),
        ("cen", "$"), ("déšť", "ne"), ("rez", "ne"), ("typ", "asijská") ]), ...
]

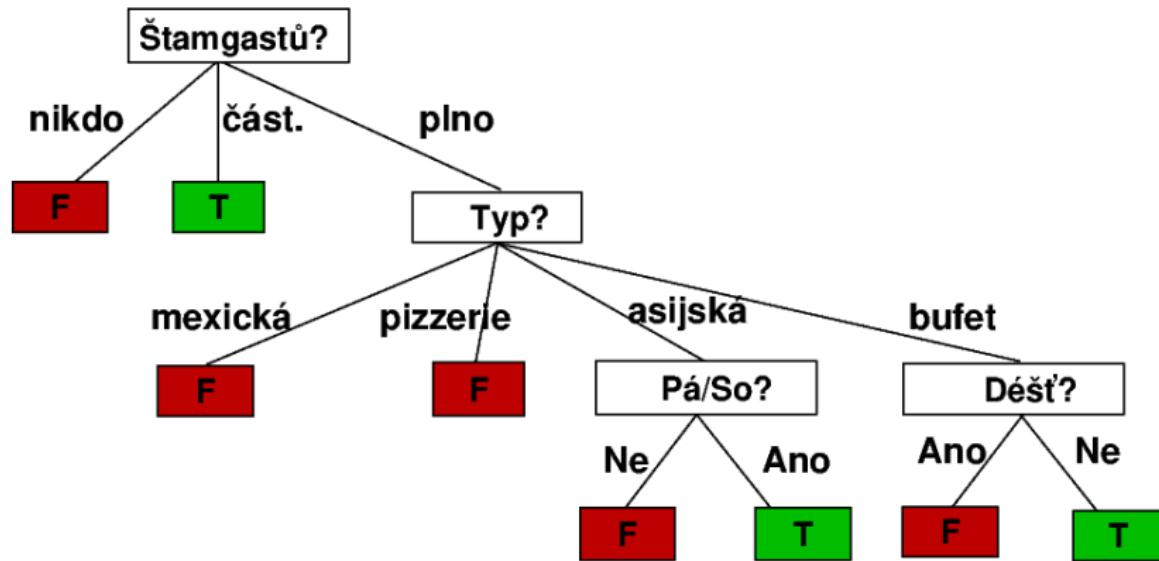
PrintTree(InduceTree(attributes, examples))

štam?
= nikdo
= nečekat
= část
= počkat
= plno
= hlad?
= ano
= cen?
= $
= páso?
= ano
= počkat
= ne
= nečekat
= $$$
= nečekat
= ne
= nečekat

```

IDT – výsledný rozhodovací strom

rozhodovací strom **naučený** z 12-ti příkladů:



podstatně jednodušší než strom "z tabulky příkladů"

Obsah

1 Učení

- Induktivní učení
- Hodnocení úspěšnosti učícího algoritmu
- Učící se agent
- Komponenta učení
- Učení – shrnutí

2 Rozhodovací stromy

- Atributová reprezentace příkladů
- Rozhodovací stromy
- Učení formou rozhodovacích stromů

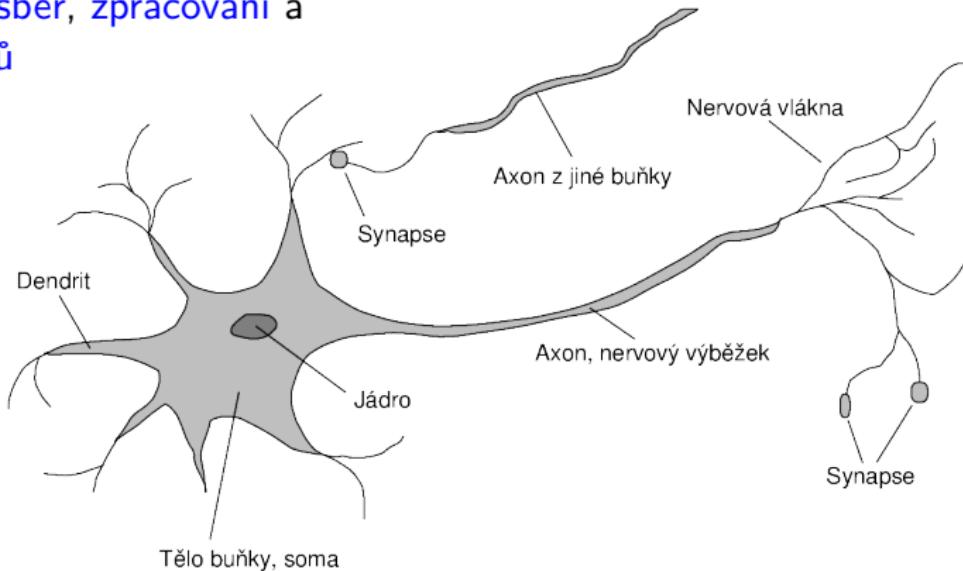
3 Neuronové sítě

- Počítačový model neuronu
- Struktury neuronových sítí

Neuron

mozek – 10^{11} neuronů > 20 typů, 10^{14} synapsí, 1ms–10ms cyklus
nosíče informace – **signály** = “výkyvy” elektrických potenciálů (se šumem)

neuron – mozková buňka, která
má za úkol **sběr**, zpracování a
šíření signálů



Počítačový model neuronu

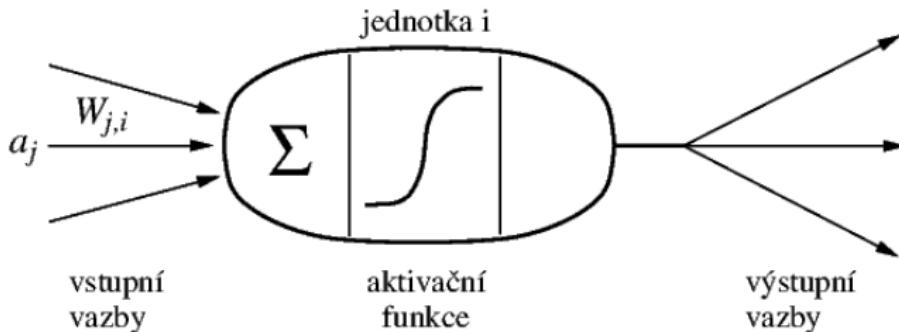
1943 – McCulloch & Pitts – matematický **model** neuronu

spojené do **neuronové sítě** – schopnost **tolerovat šum** ve vstupu a **učit se**

jednotky v neuronové síti – jsou propojeny **vazbami** (*links*)

(*units*)

- vazba z jednotky *j* do *i* propaguje **aktivaci** *a_j* jednotky *j*
- každá vazba má číselnou **váhu** *W_{j,i}* (síla+znaménko)



Počítačový model neuronu

1943 – McCulloch & Pitts – matematický **model** neuronu

spojené do **neuronové sítě** – schopnost **tolerovat šum** ve vstupu a **učit se**

jednotky v neuronové síti – jsou propojeny **vazbami** (*links*)

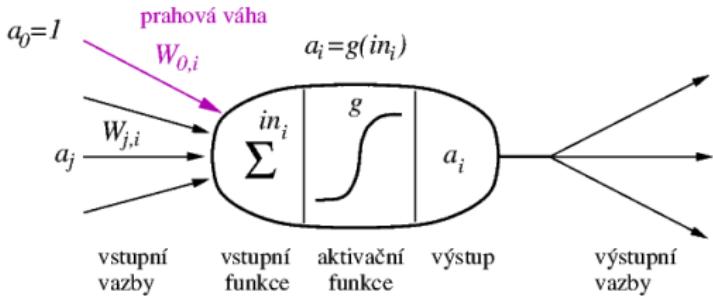
(*units*)

- vazba z jednotky *j* do *i* propaguje **aktivaci** *a_j* jednotky *j*
- každá vazba má číselnou **váhu** *W_{j,i}* (síla+znaménko)

funkce jednotky *i*:

1. spočítá váženou \sum vstupů = *in_i*
2. aplikuje **aktivační funkci** *g*
3. tím získá **výstup** *a_i*

$$a_i = g(in_i) = g\left(\sum_j W_{j,i} a_j\right)$$



Aktivační funkce

- účel **aktivační funkce**:
- jednotka má být aktivní ($\approx +1$) pro pozitivní příklady, jinak neaktivní ≈ 0
 - aktivace musí být nelineární, jinak by celá síť byla lineární

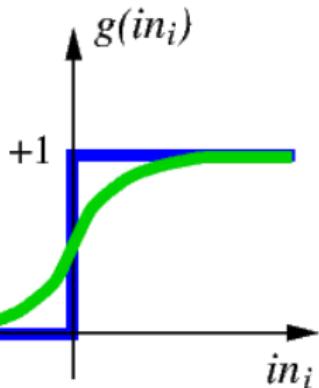
Aktivační funkce

účel **aktivační funkce**: ● jednotka má být **aktivní** ($\approx +1$) pro pozitivní příklady, jinak **neaktivní** ≈ 0

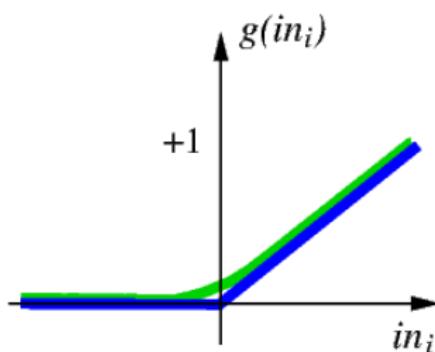
- aktivace musí být **nelineární**, jinak by celá síť byla lineární

např.

a)



b)



prahová funkce

sigmoída $1/(1 + e^{-x})$

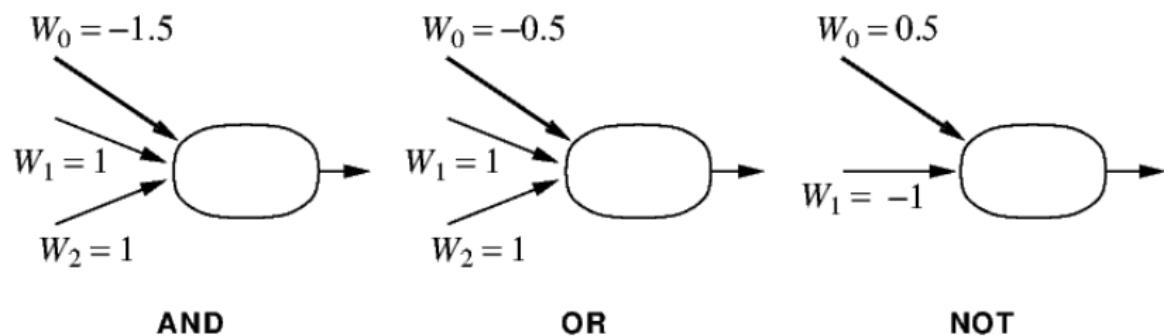
je derivovatelná – důležité pro
učení

ReLU (*rectified linear unit*)

softplus $\log(1 + e^x)$

změny **prahové váhy** $W_{0,i}$ nastavují nulovou pozici – nastavují **práh** aktivace

Logické funkce pomocí neuronové jednotky



jednotka McCulloch & Pitts sama umí implementovat **základní Booleovské funkce**

⇒ kombinacemi jednotek do sítě můžeme implementovat **libovolnou Booleovskou funkci**

Struktury neuronových sítí

- sítě s předním vstupem (*feed-forward networks*)

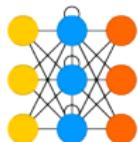
- necyklické
- implementují funkce
- nemají vnitřní paměť

- rekurentní sítě (*recurrent networks*)

- cyklické, vlastní **výstup** si berou opět na **vstup**
- složitější a schopnější
- výstup má (zpožděný) vliv na aktivaci = **paměť**
- **Hopfieldovy sítě** – symetrické obousměrné vazby; fungují jako *asociativní paměť*
- **Boltzmannovy stroje** – pravděpodobnostní aktivační funkce
- **Long Short Term Memory (LSTM)** – spojují vzdálené závislosti v sekvenci vstupu

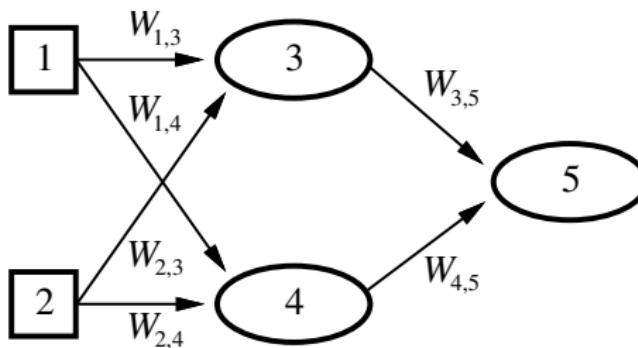


www.asimovinstitute.org/neural-network-zoo



Příklad sítě s předním vstupem

sítě 5-ti jednotek – **2 vstupní** jednotky, **1 skrytá vrstva** (2 jednotky), **1 výstupní** jednotka



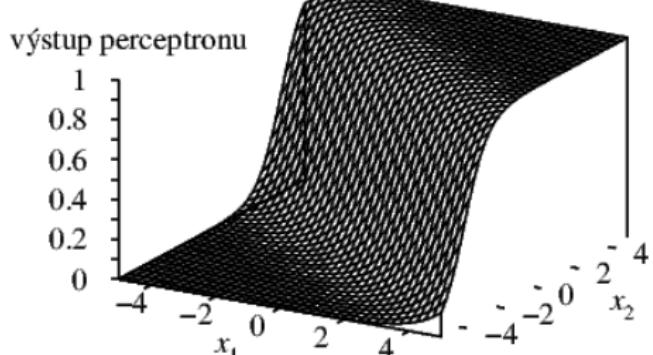
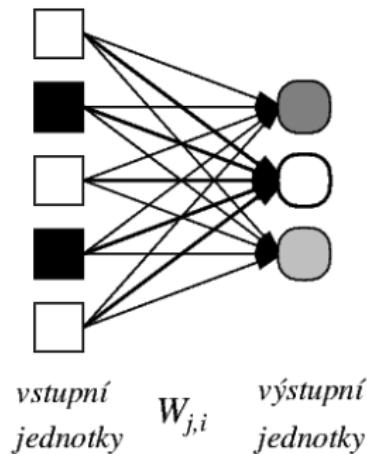
sítě s předním vstupem = **parametrizovaná** nelineární funkce vstupu

$$\begin{aligned}
 a_5 &= g(W_{3,5} \cdot a_3 + W_{4,5} \cdot a_4) \\
 &= g(W_{3,5} \cdot g(W_{1,3} \cdot a_1 + W_{2,3} \cdot a_2) + W_{4,5} \cdot g(W_{1,4} \cdot a_1 + W_{2,4} \cdot a_2))
 \end{aligned}$$

Jednovrstvá síť – perceptron

perceptron

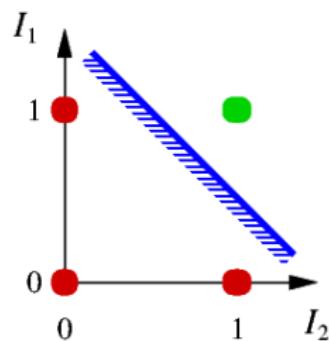
- pro Booleovskou funkci 1 výstupní jednotka
- pro složitější klasifikaci – **více výstupních jednotek**



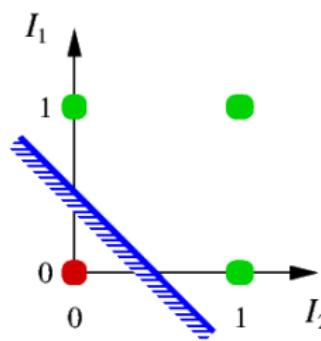
Vyjadřovací síla perceptronu

perceptron může reprezentovat hodně Booleovských funkcí – AND, OR, NOT, majoritní funkci ($\sum_j W_j x_j > n/2, W_j = 1$), ...

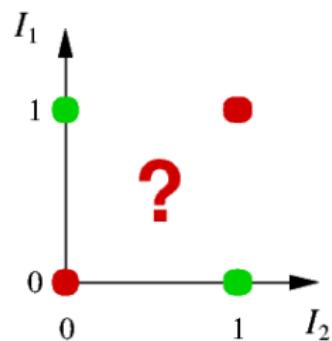
reprezentuje **lineární separátor** (nadrovina) v prostoru vstupu:



a) I_1 and I_2



b) I_1 or I_2



c) I_1 xor I_2

Učení perceptronu

výhoda perceptronu – existuje jednoduchý **učící algoritmus** pro libovolnou lineárně separabilní funkci

učení perceptronu = upravování vah, aby se **snížila chyba** na trénovací sadě

Učení perceptronu

výhoda perceptronu – existuje jednoduchý **učící algoritmus** pro libovolnou lineárně separabilní funkci

učení perceptronu = upravování vah, aby se **snížila chyba** na trénovací sadě

kvadratická chyba (ztráta, *Loss*) **E** pro příklad se vstupem **x** a požadovaným (=správným) výstupem **y** je

$$E = \frac{1}{2} Err^2 \equiv \frac{1}{2}(y - h_w(x))^2, \quad \text{kde } h_w(x) \text{ je výstup perceptronu}$$

Učení perceptronu

výhoda perceptronu – existuje jednoduchý **učící algoritmus** pro libovolnou lineárně separabilní funkci

učení perceptronu = upravování vah, aby se **snížila chyba** na trénovací sadě

kvadratická chyba (ztráta, *Loss*) E pro příklad se vstupem \mathbf{x} a požadovaným (=správným) výstupem y je

$$E = \frac{1}{2} Err^2 \equiv \frac{1}{2}(y - h_{\mathbf{W}}(\mathbf{x}))^2, \quad \text{kde } h_{\mathbf{W}}(\mathbf{x}) \text{ je výstup perceptronu}$$

váhy pro minimální chybu pak hledáme **optimalizačním prohledáváním** spojitého prostoru vah

$$\frac{\partial E}{\partial W_j} = Err \times \frac{\partial Err}{\partial W_j} = Err \times \frac{\partial}{\partial W_j} (y - g(\sum_{j=0}^n W_j x_j)) = -Err \times g'(in) \times x_j$$

pravidlo pro úpravu váhy

$$W_j \leftarrow W_j + \alpha \times Err \times g'(in) \times x_j \quad \alpha \dots \text{učící konstanta (learning rate)}$$

např. $Err = y - h_{\mathbf{W}}(\mathbf{x}) > 0 \Rightarrow$ výstup $h_{\mathbf{W}}(\mathbf{x})$ je moc malý

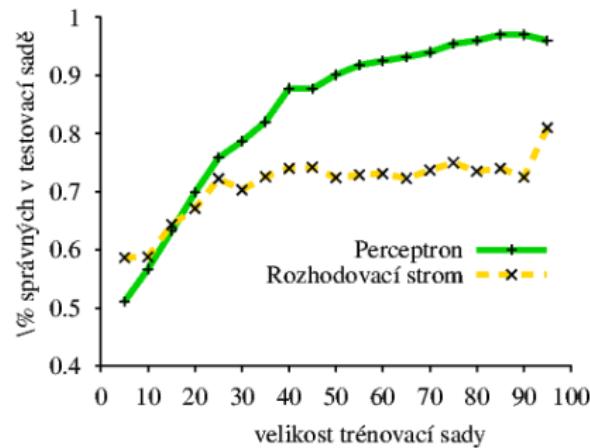
\Rightarrow váhy se musí **zvýšit** pro pozitivní příklady a **snížit** pro negativní

úpravu vah provádíme po každém příkladu \rightarrow opakováně až do dosažení ukončovacího kritéria

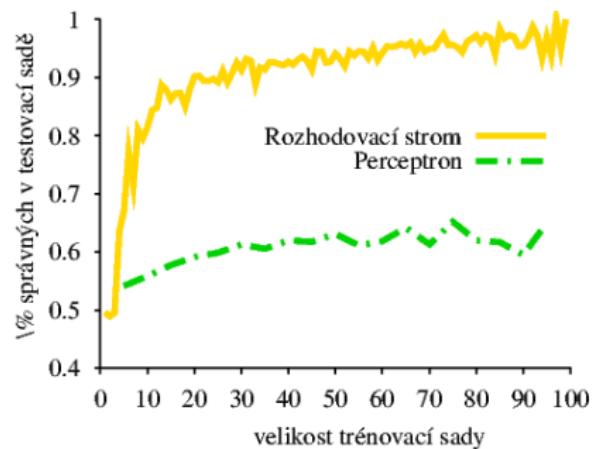
Učení perceptronu pokrač.

učící pravidlo pro perceptron **konverguje ke správné funkci** pro libovolnou **lineárně separabilní** množinu dat

a) učení majoritní funkce



b) učení čekání na volný stůl v restauraci



Vícevrstvé neuronové sítě

označení **MLP**, multi-layer perceptron

vrstvy jsou obvykle **úplně propojené**
počet **skrytých jednotek** je obvykle volen experimentálně

výstupní jednotky

a_i

$W_{j,i}$

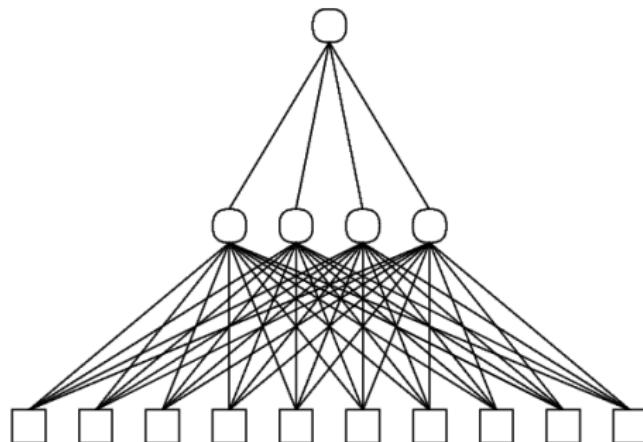
skryté jednotky

a_j

$W_{k,j}$

vstupní jednotky

a_k



Vyjadřovací síla vícevrstvých sítí

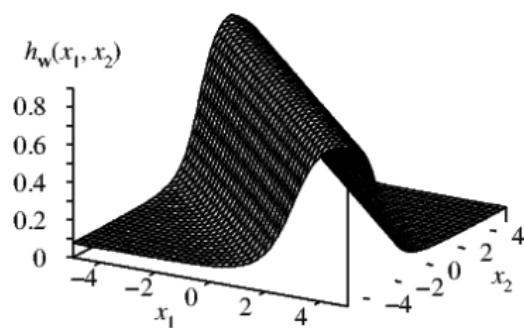
s jednou skrytou vrstvou – všechny spojité funkce

se dvěma skrytými vrstvami – všechny funkce

těžko se ovšem pro konkrétní síť zjišťuje její prostor reprezentovatelných funkcí

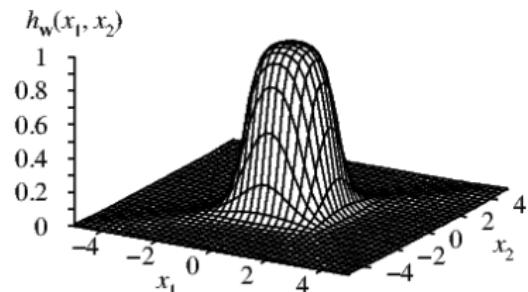
např.

dvě “opačné” skryté jednotky
vytvoří hřbet



playground.tensorflow.org

dva hřbety vytvoří *homoli*



SliDo

Učení vícevrstvých sítí

pravidla pro úpravu vah:

- výstupní vrstva – stejně jako u perceptronu

$$W_{j,i} \leftarrow W_{j,i} + \alpha \times a_j \times \Delta_i \quad \text{kde} \quad \Delta_i = Err_i \times \mathbf{g}'(in_i)$$

Učení vícevrstvých sítí

pravidla pro úpravu vah:

- výstupní vrstva – stejně jako u perceptronu

$$W_{j,i} \leftarrow W_{j,i} + \alpha \times a_j \times \Delta_i \quad \text{kde} \quad \Delta_i = Err_i \times \mathbf{g}'(in_i)$$

- skryté vrstvy – **zpětné šíření** (*back-propagation*) chyby z výstupní vrstvy

$$W_{k,j} \leftarrow W_{k,j} + \alpha \times a_k \times \Delta_j \quad \text{kde} \quad \Delta_j = \mathbf{g}'(in_j) \sum_i W_{j,i} \Delta_i$$

Učení vícevrstvých sítí

pravidla pro úpravu vah:

- výstupní vrstva – stejně jako u perceptronu

$$W_{j,i} \leftarrow W_{j,i} + \alpha \times a_j \times \Delta_i \quad \text{kde} \quad \Delta_i = Err_i \times \mathbf{g}'(in_i)$$

- skryté vrstvy – **zpětné šíření** (*back-propagation*) chyby z výstupní vrstvy

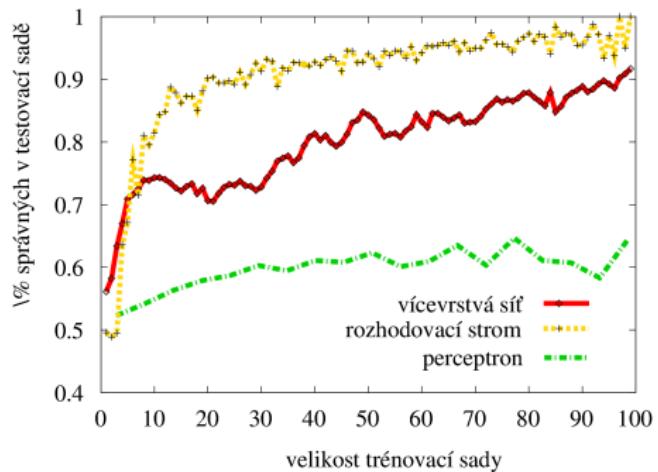
$$W_{k,j} \leftarrow W_{k,j} + \alpha \times a_k \times \Delta_j \quad \text{kde} \quad \Delta_j = \mathbf{g}'(in_j) \sum_i W_{j,i} \Delta_i$$

problémy učení:

- dosažení **lokálního minima** chyby
- příliš **pomalá konvergence**
- přílišné **upnutí** na příklady → neschopnost generalizovat

Učení vícevrstvých sítí pokrač.

vícevrstvá síť se problém čekání na volný stůl v restauraci učí znatelně líp než perceptron



Neuronové sítě – shrnutí

- většina mozků má velké množství neuronů; každý **neuron** ≈ lineární prahová jednotka (?)
- **perceptrony** (jednovrstvé sítě) mají nízkou vyjadřovací sílu
- **vícevrstvé sítě** jsou dostatečně silné; mohou být trénovány pomocí zpětného šíření chyby
- velké množství reálných aplikací
 - rozpoznávání řeči
 - rozpoznávání ručně psaného písma
 - řízení auta, ...

Neuronové sítě – shrnutí

- většina mozků má **velké množství** neuronů; každý **neuron** \approx lineární prahová jednotka (?)
- **perceptrony** (jednovrstvé sítě) mají **nízkou** vyjadřovací sílu
- **vícevrstvé sítě** jsou **dostatečně silné**; mohou být trénovány pomocí zpětného šíření chyby
- velké množství reálných aplikací
 - rozpoznávání řeči
 - rozpoznávání ručně psaného písma
 - řízení auta, ...
- v posledních letech **hluboké neuronové sítě** – lépe **generalizují**

