

# Metody strojového učení

P. Bastl<sup>1</sup>, J. Kučera<sup>2</sup>, D. Léwová<sup>3</sup>

<sup>1</sup>Gymn. Vídeňská, Brno

<sup>2</sup>SGAGY, Kladno

<sup>3</sup>SŠ Výpočetní techniky, Praha

[petr.bastl@seznam.cz](mailto:petr.bastl@seznam.cz)

[kuc.jan@seznam.cz](mailto:kuc.jan@seznam.cz)

[vlew@volny.cz](mailto:vlew@volny.cz)

## Abstrakt:

Strojové učení (machine learning) je oblast matematiky a informatiky zkoumající metody učení strojů. Oblast využití strojového učení pokrývá v podstatě všechny obory lidské činnosti (lékařství, výzkum vesmíru, expertní systémy, robotika). V příspěvku uvedeme základní směry a metody strojového učení.


## 1 Úvod

S příchodem nových technologií a množstvím informací vzrůstá potřeba automatického zpracování a analyzování dat. Touto problematikou se, mimo jiné, zabývá takzvané strojové učení. V miniprojektu jsme se seznámili se základními metodami strojového učení a aplikacemi na jednoduchých příkladech.

## 2 Popis vybraných metod strojového učení


Jedním ze základních problémů strojového učení je klasifikační problém, což je problém přiřazení tříd objektům (rozpoznání jednotlivých objektů). Aby bylo možné objekty rozpoznávat je nutné nejdříve je popsat. To lze provádět dvěma způsoby:

- 1) Pomocí příznaků (parametrů)....( $X_1, \dots, X_n$ )



: např. parametry  $x_2$  a  $x_1$  - šířka a výška

Každým bodem v parametrickém prostoru je určen jeden objekt. Objekty s podobnými parametry se budou shlukovat v tzv. shlucích ( hloučkách ). Při použití dvou určujících parametrů se hloučky tvoří v rovině (2D), při použití třech parametrů budou hloučky v prostoru (3D), atd.



- 2) Pomocí popisu struktury objektu – např. pomocí formálního jazyka popsat tvar objektů.


K tomu, aby stroj mohl řešit problémy musí se to nejdříve naučit. V praxi se využívají dva základní směry ( přístupy )

- 1) Prvním směrem je *učení s učitelem*. Stroji se předkládají objekty se známou klasifikací, které si „zapamatuje“ a je schopen podle nich zařadit neznámý objekt do definovaných tříd. (př.: Tohle je kruh, tohle je elipsa.) Je to poměrně časově náročné a s rizikem, že učitel přiřadí objekt do špatné třídy ( chyba v trénovacích datech ).
- 2) Dalším používaným směrem je *učení bez učitele*. V tomto případě stroj musí nejdříve v parametrickém prostoru odhalit třídy objektů. Například pomocí vyhledávání shluků v parametrickém prostoru-*shluková analýza, hierarchické shlukování*.

### Metody strojového učení :

#### 1. Statistické metody :


- *Bayesův klasifikátor* – ze znalosti parametrů učicích dat odhaduje pravděpodobnost třídy neznámého objektu
- *NN*(Nearest Neighbour = „nejbližší soused“) - neznámý objekt zařadí podle nejbližšího prvku se známou klasifikací .




Tato metoda je ovšem dosti nachylna k „sumě“ (chyby v učicí množině), proto se na zlepšení metody vyhledává *k* nejbližších prvků, tato modifikace se nazývá *k*-NN.

2. Umělé neuronové sítě : Myšlenka vytvoření neuronové sítě, jako paralelní výpočetní jednotky, vznikla v 40. letech 20 století a byla inspirovaná přírodou – biologickou neuronovou sítí. Hlavním problémem při konstrukci neuronové sítě je volba její architektury. V současnosti se hlavně používá dopředná architektura ( vrstevnaté sítě ), protože existuje algoritmus na učení takovýchto sítí založen na minimalizaci chyby na výstupu sítě ( backpropagation, algoritmus zpětného šíření ).

Ovšem existují a používají se i jiné architektury neuronových sítí např.: rekurentní, Hopfieldův model, Kohonenovy mapy.



Dopředná topologie




Rekurentní topologie

Učení neuronových sítí spočívá v nastavování jejich parametrů na základě znalosti trénovací množiny.

Přesněji je neuronová síť orientovaným grafem, tvořeným množinou neuronů (perceptronů) a spojů (synapsí, hran) mezi nimi.

Nejčastějším modelem neuronu je takzvaný perceptron, jehož stručný popis následuje:

$(x_1 \dots x_n)$  jsou vstupy neuronu, na každém vstupu je váha spoje  $w_1 \dots w_n$  „důležitost“ ( $x_i \cdot w_i$  zesílí nebo zeslabí vstupní signál)



:neuron

$$y = \frac{1}{1 + e^{-x}}$$

:příklad sigmoidální funkce

Tělo neuronu je tvořeno aktivační funkcí  $f$  a prahem  $t$ :


Výstupem perceptronu je hodnota  $y = f(\sum x_i \cdot w_i - t)$

Nejjednodušší používanou aktivační funkcí je tzv. tvrdá nelinearita:


$$F(z) = \begin{cases} -1 & z \geq 0 \\ 0 & z < 0 \end{cases}$$

Používají se však i jiné aktivační funkce například tzv. sigmoidální funkce nebo RBF funkce.

Jeden perceptron rozděluje příznakový prostor podle nadroviny, tudíž umí klasifikovat pouze lineárně separabilní množiny. Nejjednodušší množinou, která není lineárně separabilní je množina XOR (nonekvivalence)




: nadroviny



:lin. neseparabilní množina (XOR)

### 3. Rozhodovací stromy a lesy :

Rozhodovací strom je acyklický orientovaný graf se dvěma typy uzlů (rozhodovací uzel nebo list). Neznámý případ prochází testy v rozhodovacích uzlech podle jeho parametrů až dosáhne listu, který rozhodne o jeho zařazení do třídy. Pro zlepšení klasifikace se používá propojení několika rozhodovacích stromů do tzv. rozhodovacích lesů. Pak se výsledek udává pravidlem kombinování predikcí jednotlivých stromů (např. většinou).



: příklad stromu řešícího XOR

#### 4. Genetické algoritmy :

Genetický algoritmus je nedeterministický prohledávací algoritmus pracující s velkou populací n-jedinců. Inspirace se opět vzala z přírody - evolučního vývoje.

Genetické algoritmy jsou založeny na velkém počtu jedinců z nichž přežívají jenom ti nejsilnější (nejlepší řešení). Populace v průběhu času prochází vývojem, který se v každém okamžiku skládá ze tří hlavních kroků

- 1) Selekcce - výběr rodičů
- 2) Křížení - kombinace vlastností rodičů a vznik nového jedince
- 3) Mutace - náhodná změna kódu.

Kvalita jedinců se určuje ohodnocovací (fitness) funkcí. Z věty o schématech plyne, že v populaci se exponenciálně množí jedinci s nadprůměrnou hodnotou fitness tzn. Že algoritmus konverguje ke správnému řešení.

## 3 Shrnutí

Strojové učení je zajímavým oborem moderní vědy. V dnešní době s rozvojem výkonných počítačů zažívá tento obor velký rozvoj a i do budoucnosti lze očekávat nárůst poptávky po tomto druhu algoritmů.

## Poděkování

Poděkování fakultě jaderné a fyzikálně inženýrské ČVUT a supervizorovi ing. Emilu Kotrčovi z katedry matematiky.

## Reference:

- [1] Sinčák P. & Andrejková G. Neurónové siete -Inžiniersky prístup
- [2] Neruda, ŠÍMA: TEORETICKÉ OTÁZKY NS
- [3] <http://cs.felk.cvut.cz/~xobitko/ga/>
- [4] <http://www.aic.nrl.navy.mil/~aha/research/machine-learning.html>