

PREDSLOV

Táto vysokoškolská učebnica vznikla ako podklad ku výučbe predmetu Umelá inteligencia na Katedre riadiacich a informačných systémov Žilinskej univerzity. Vznikala postupne, počas troch rokov, ako odpoveď na potrebu existencie súhrnného materiálu obsahujúceho v kompaktnej forme základné poznatky o oblastiach, ktorým sa predmet venuje.

Hoci stavba učebnice je prispôsobená osnove konkrétneho predmetu, možno ju použiť aj samostatne – ako materiál, ktorý v dostupnej a pomerne jednoduchej forme prezentuje vybrané základné témy z oblasti umelej inteligencie.

K samotnému predmetu existuje už predchádzajúca učebnica – Rozhodovanie a riadenie s podporou umelej inteligencie [1] – ktorá poskytuje veľmi dobrý prehľad o viacerých prístupoch a metódach z oblasti umelej inteligencie. Bola vydaná v roku 2005.

Cieľom novej učebnice nie je tento existujúci materiál nahradiť. Sledujeme dva ciele: Prvým je zaplniť biele miesta, keďže predchádzajúca učebnica sa nevenuje viacerým perspektívnym oblastiam, ani nepokrýva všetky témy, ktoré sa v súčasnosti na predmete preberajú.

Druhým cieľom je poskytnúť znalosti v dostupnej forme a takým spôsobom, aby ich bolo možné ľahko aplikovať. Učebnica preto kombinuje teoretický výklad s príkladmi – nielen výpočtovými, ale aj aplikačnými. Priložené sú zdrojové kódy pre prostredie Matlab a programovací jazyk Python, ktoré nielen ilustrujú jednotlivé metódy, ale predovšetkým ukazujú ako ich možno použiť.

Prvá časť učebnice obsahuje dve veľké kapitoly – jednu na tému fuzzy prístupov, ktoré slúžia ako nástroj na formalizáciu vágnych poznatkov a druhú na tému umelých neurónových sietí, ktoré bezpochyby patria medzi najznámejšie prístupy v oblasti umelej inteligencie a možno ich aplikovať na širokú škálu úloh.


Medzi ciele učebnice nepatrí poskytnúť vyčerpávajúci prehľad diskutovaných oblastí – bola by to nielen nadľudská, ale predovšetkým zbytočná námaha. Podrobných materiálov ku jednotlivým témam je dostatok. Našou úlohou je však poskytnúť čitateľovi dostatočný základ na to,

aby ich dokázal študovať samostatne. V texte sa preto priebežne vyskytujú citácie, odkazujúce na práce, venujúce sa danej problematike podrobnejšie. V závere kapitol je navyše vyhradená časť na odporúčanie ďalšej literatúry, online kurzov, softvérových nástrojov a podobne.

Niet pochyb, že na seriózne štúdium metód umelej inteligencie je v súčasnosti nevyhnutná znalosť anglického jazyka. Prechod ku anglickým textom sa preto učebnica snaží uľahčiť zavedením slovensko-anglického slovníka pojmov. Tento by mal pomôcť identifikovať anglické ekvivalenty ku hlavným diskutovaným termínom.

POZNÁMKA | Poznámky

Učebnica na niektorých miestach obsahuje poznámky, ktoré ilustrujú a do-
vysvetľujú zmysel textu.

V elektronickej verzii knihy sú na viacerých miestach k textu priložené sú-
bory – tieto sú označené . Extrahovať ich možno typicky buď ľavým alebo
pravým kliknutím (v závislosti od konkrétnej aplikácie).

Predslov	i
Slovník pojmov	viii
1 Strojové učenie	1
1.1 Zovšeobecnenie	2
1.2 Typy učenia: rozdelenie podľa typu úlohy	3
1.2.1 Kontrolované učenie	4
1.2.2 Učenie s odmenou	5
1.2.3 Nekomtrolované učenie	5
1.2.4 Čiastočne kontrolované učenie	8
1.3 Znalosti	8
1.3.1 Implicitné a explicitné znalosti	9
1.3.2 Top-down a bottom-up učenie	10
2 Fuzzy prístupy	11
2.1 Teória fuzzy množín	12
2.1.1 Stupeň príslušnosti a funkcia príslušnosti	13
2.1.2 Spojité a diskrétne fuzzy množiny	14
2.1.3 Spôsoby zápisu fuzzy množín	14
2.1.4 Singleton	16
2.1.5 Charakteristiky fuzzy množín	16
2.1.6 Konvexná fuzzy množina	20
2.1.7 Normálna, subnormálna a prázdna fuzzy množina	20
2.1.8 Operácie s klasickými množinami	21
2.1.9 Operácie s fuzzy množinami	22

2.1.10	Ďalšie príklady	25
2.2	Približné uvažovanie – fuzzy logika	26
2.2.1	Lingvistická premenná	26
2.2.2	Fuzzy inferenčný systém	27
2.2.3	Báza pravidiel	28
2.2.4	Fuzzifikácia	28
2.2.5	Inferencia	29
2.2.6	Agregácia	30
2.2.7	Defuzzifikácia	31
2.2.8	Agregácia zjednotením vs. SUM agregácia	33
2.2.9	Ďalšie metódy inferencie	35
2.3	Fuzzy regulátory	40
2.3.1	Predpoklady pri návrhu fuzzy regulátorov	40
2.3.2	Postup návrhu fuzzy regulátora	41
2.3.3	Klasifikácia fuzzy regulátorov	41
2.3.4	Klasické PID a PSD regulátory	44
2.3.5	Fuzzy regulátory PID typu	45
2.4	Fuzzy aritmetika	49
2.4.1	Fuzzy čísla	50
2.4.2	Princíp rozšírenia	50
2.4.3	Spôsoby zápisu fuzzy čísel	51
2.4.4	L-R fuzzy čísla	52
2.4.5	Rozložené fuzzy čísla	57
2.4.6	Fuzzy aritmetika v prostredí Matlab a Python	67
	Kam ďalej?	71
3	Umelé neurónové siete	77
3.1	Model a základná teória	77
3.1.1	Biologický neurón	77
3.1.2	Umelý neurón	78
3.1.3	Aktivačná funkcia	79
3.1.4	Problém lineárnej separovateľnosti	81
3.1.5	Umelá neurónová sieť	84
3.2	Učenie ANN – úvod	88
3.2.1	Iteratívne učenie	88
3.3	Kontrolované učenie	89
3.3.1	Metóda klesajúceho gradientu	89

3.3.2	Delta pravidlo	98
3.3.3	Princíp spätného šírenia chyby	102
3.3.4	Delta pravidlo, backpropagation – zhrnutie	103
3.3.5	Dávkové, inkrementálne a mini dávkové učenie	104
3.3.6	Nadstavbové metódy	106
3.3.7	Klasifikácia	113
3.3.8	Regresia	119
3.3.9	Predikcia časových radov	121
3.3.10	Zovšeobecnenie	124
3.3.11	Ako voliť počet neurónov a vrstiev?	129
3.4	Nekontrolované učenie	129
3.4.1	Konkurenčné učenie	129
3.4.2	Samoorganizujúce sa mapy	140
3.5	Neurónové siete v automatickom riadení	143
3.5.1	Aproximácia funkcií	143
3.5.2	Inverzné riadenie	144
3.5.3	Adaptívne riadenie s referenčným modelom	148
3.5.4	Prediktívne riadenie	148
	Kam ďalej?	151

SKRATKY

- AN:** umelý neurón (angl. artificial neuron), pp. 78, 80
- ANFIS:** adaptívny neuro-fuzzy inferenčný systém, p. 43
- ANN:** umelá neurónová sieť (angl. artificial neural network), pp. 84, 88, 119, 125, 144, 147–152
- BFGS:** Broyden–Fletcher–Goldfarb–Shanno algoritmus, p. 149
- CoA:** metóda ťažiska (angl. centre of area); tiež CoG, p. 31
- CoG:** metóda ťažiska (angl. centre of gravity); tiež CoA, pp. 31, 34
- DIKW:** dáta-informácie-znalosti-múdrosť pyramída (angl. data-information-knowledge-wisdom pyramid), pp. 8, 9
- FIR:** filter s konečnou impulznou odozvou (angl. finite impulse response); v slovenskej literatúre aj KIO, p. 145
- FIS:** fuzzy inferenčný systém, pp. 27, 28, 46, 47, 73, 75
- FLC:** fuzzy regulátor (angl. fuzzy logic controller), p. 40
- FM:** fuzzy množina, pp. 13, 14, 16, 24, 32, 40, 50
- FoM:** prvé z maxím (angl. first of maxima), pp. 32, 33

- GPGPU:** univerzálne výpočty na grafických kartách (angl. general-purpose computing on graphics processing units), p. 86
- GPU:** grafická karta (angl. graphics processing unit), p. 86
- HM:** metóda výšok (angl. height method), p. 31
- LoM:** posledné z maxím (angl. last of maxima), pp. 32, 33
- MIMO:** viac vstupov – viac výstupov (angl. multi input multi output), p. 41
- MISO:** viac vstupov – jeden výstup (angl. multi input single output), p. 41
- MLP:** viacvrstvový perceptrón, viacvrstvová neurónová sieť (angl. multi-layer perceptron), p. 86
- MoM:** stred maxím (angl. middle of maxima), p. 33
- P:** proporcionálny regulátor, pp. 44–48, 147
- PD:** proporcionálno derivačný; proporcionálno diferenčný (regulátor), pp. 44–49
- PI:** proporcionálno integračný (regulátor), pp. 44, 45, 49
- PID:** proporcionálno integračno derivačný (regulátor), pp. 42, 44, 45, 48, 71, 72
- PS:** proporcionálno sumačný (regulátor), pp. 45–48
- PSD:** proporcionálno sumačno diferenčný (regulátor), pp. 44, 45, 47–49
- SAR:** systémy automatického riadenia, pp. 143, 144
- SGD:** stochastický klesajúci gradient (angl. stochastic gradient descent), p. 105
- SISO:** jeden vstup – jeden výstup (angl. single input single output), p. 41
- SOM:** samoorganizujúca sa mapa (angl. self-organising map), pp. 140, 142
- T-S:** metóda Takagi-Sugeno, pp. 38, 43, 44

SLOVNÍK POJMOV

Alfa hladina: alpha level.

Alfa rez: alpha cut.

Báza pravidiel: rule base.

Čiastočne kontrolované učenie: semi-supervised learning.

Defuzzifikácia: defuzzification.

Doplňok: complement.

Učenie pomocou komisií: ensemble learning.

Fuzzy inferenčný systém: fuzzy inference system.

Fuzzifikácia: fuzzification.

Fuzzy číslo: fuzzy number.

Fuzzy interval: fuzzy interval.

Jadro: kernel core.

Kompetitívne učenie: competitive learning.

Konkurenčné učenie: competitive learning.

Kontrolované učenie: supervised learning.

Lingvistická hodnota: linguistic value.

Lingvistická premenná: linguistic variable.

Metóda ťažiska: centre of gravity (CoG) resp. centre of area (CoA). Tiež centroid method.

Metóda výšok: height method (HM). Tiež max membership principle.

Nekontrolované učenie: unsupervised learning.

Umelá neurónová sieť: artificial neural network (ANN).

Normálna fuzzy množina: normal fuzzy set.

Nosič: support.

Ostrá hodnota: crisp value.

Prienik: intersection.

Prvé z maxím: first of maxima (FoM).

Samoorganizujúca mapa: self-organising map.

Stred maxím: middle of maxima (MoM).

Stupeň príslušnosti: degree of membership.

Subnormálna fuzzy množina: subnormal fuzzy set.

T-konorma: T-conorm.

T-norma: T-norm.

Učenie bez predlohy: unsupervised learning.

Učenie bez učiteľa: learning without a teacher.

Učenie s odmenou: reinforcement learning.

Učenie s predlohou: supervised learning.

Učenie s učiteľom: learning with a teacher.

Umelý neurón: artificial neuron (AN).

Univerzum: universe of discourse.

Vrchol: peak.

Vrstvená sieť: layered network.

Výška: height.

Zákonitosti: regularities.

Zjednotenie: union.

ZOZNAM OBRÁZKOV

1.1	Strojové učenie – pojmy.	2
1.2	Je lokálne zovšeobecnenie postačujúce?	3
1.3	Kontrolované učenie – klasifikácia.	5
1.4	Učenie s odmenou: sekvenčné rozhodovanie.	6
1.5	Zhlukovanie – tri zhluky a systém vykonávajúci klasifikáciu.	6
1.6	Vektorová kvantizácia.	7
1.7	DIKW pyramída – dáta, informácie, znalosti, múdrosť.	9
2.1	Po koľkých odhryznutiach sa stáva z jablka ohryzok?	14
2.2	Diskrétna fuzzy množina, grafické znázornenie.	15
2.3	Grafické znázornenie spojitej fuzzy množiny.	15
2.4	Lingvistická premenná výška človeka a jej lingvistické hodnoty.	27
2.5	Fuzzy inferenčný systém – bloková schéma.	28
2.6	Mamdaniho inferencia.	30
2.7	Metóda ťažiska.	32
2.8	Metóda výšok.	32
2.9	Metóda váženého priemeru.	32
2.10	Prvé z maxím.	33
2.11	Stred maxím.	33
2.12	Posledné z maxím.	33
2.13	Stred najväčšej plochy.	34
2.14	Agregácia – prvý scenár.	34
2.15	Agregácia – druhý scenár.	34
2.16	Mamdaniho metóda.	36
2.17	Larsenova metóda.	36

2.18	Tsukamotova metóda.	39
2.19	Metóda Sugeno-Takagi.	39
2.20	Yagerova metóda.	40
2.21	Fuzzy regulátor typu P.	46
2.22	Fuzzy PD regulátor.	47
2.23	Fuzzy regulátor typu PS.	47
2.24	Fuzzy regulátor typu PSD.	48
2.25	Fuzzy PSD s 1 vstupom; rozšírená architektúra, 1 regulátor.	48
2.26	Fuzzy PSD s 1 vstupom; rozšírená architektúra, 3 regulátory.	49
2.27	Príklad – fuzzy číslo.	50
2.28	Príklad – fuzzy interval.	50
2.29	L-R reprezentácia fuzzy čísla.	52
2.30	Reprezentácia funkcie príslušnosti pomocou α -rezov.	57
2.31	Trojuholníkové fuzzy čísla $\tilde{2} = \text{tfn}(2, 1, 1)$ a $\tilde{3} = \text{tfn}(3, 1, 1)$	59
2.32	Výpočet elementárnych aritmetických operácií pomocou rozkladu čísla na α -rezy.	62
2.33	Zobrazenie prvkov množiny M pre násobenie fuzzy čísel $\tilde{2}$ a $\tilde{3}$	64
2.34	Zobrazenie prvkov množiny D pre delenie fuzzy čísel $\tilde{2}$ a $\tilde{3}$	67
2.35	Grafický výstup programu z Lst. 4.	70
3.1	Biologický neurón.	78
3.2	Umelý neurón.	79
3.3	Znamienková funkcia $\text{sgn}(x)$	80
3.4	Aktivačná funkcia $\tanh(x)$	80
3.5	Sigmoidná funkcia.	80
3.6	Separácia vstupného priestoru.	82
3.7	Separácia vstupného priestoru funkcie OR.	83
3.8	Separácia vstupného priestoru funkcie XOR.	83
3.9	Kombinácia perceptrónov s logickým členom AND.	84
3.10	Náhrada logického člena AND perceptrónom.	84
3.11	Dopredná architektúra.	85
3.12	Rekurentná sieť (na obrázku špeciálny prípad, tzv. Jordanova sieť).	85
3.13	Iteratívny priebeh učenia.	89
3.14	Funkcia $f(x, y)$	91
3.15	Bočný rez funkcie $f(x, y)$ pre $y = 0$	91
3.16	Minimalizácia metódou klesajúceho gradientu.	93
3.17	Minimalizácia metódou klesajúceho gradientu: bočný rez.	93
3.18	Príklad funkcie s veľkým počtom lokálnych miním.	97

3.19 Sieť s l vrstvami.	100
3.20 Inkrementálne učenie.	105
3.21 Dávkové učenie.	105
3.22 Chybový povrch v tvare paraboloidu.	106
3.23 Chybový povrch v tvare paraboloidu – vrstevnicový graf.	107
3.24 Chybový povrch v tvare rozťahnutého paraboloidu.	108
3.25 Chybový povrch v tvare rozťahnutého paraboloidu – vrstevnicový graf.	108
3.26 Minimalizácia na rozťahnutom paraboloidu. Dochádza ku oscilácii v smere w_1	109
3.27 $E(W)$ v čase: metóda klesajúceho gradientu bez použitia hybnosti.	110
3.28 $E(W)$ v čase: metóda klesajúceho gradientu s použitím hybnosti.	110
3.29 Minimalizácia na rozťahnutom paraboloidu s použitím hybnosti.	110
3.30 Minimalizácia na rozťahnutom paraboloidu bez hybnosti s $\lambda = 0,005$	110
3.31 Minimalizácia na rozťahnutom paraboloidu s použitím hybnosti – vrstevnicový graf.	111
3.32 Minimalizácia na rozťahnutom paraboloidu bez hybnosti s $\lambda = 0,005$ – vrstevnicový graf.	111
3.33 Minimalizácia na rozťahnutom paraboloidu s použitím hybnosti – chyba $E(W)$ v čase.	111
3.34 Minimalizácia na rozťahnutom paraboloidu bez hybnosti s $\lambda = 0,005$ – chyba $E(W)$ v čase.	111
3.35 Polynomická regresia so stupňom polynómu 3.	127
3.36 Polynomická regresia so stupňom polynómu 7.	127
3.37 Polynomická regresia so stupňom polynómu 10.	127
3.38 Polynomická regresia so stupňom polynómu 15.	127
3.39 Vizualizácia regresnej závislosti z Lst. 11.	128
3.40 Vizualizácia regresnej závislosti z Lst. 11 s 30 a 30 skrytými neurónmi.	128
3.41 Príklad siete s konkurenčným učením.	130
3.42 Konkurenčné učenie – príklad.	132
3.43 Topológia MAXNET.	138
3.44 Kompetitívne učenie – 2-rozmerný prípad.	139
3.45 Presakujúce konkurenčné učenie – príklad.	141
3.46 SOM – topológia.	142
3.47 Aproximácia neznámej funkcie v SAR na báze ANN.	144
3.48 Princíp inverzného riadenia.	145
3.49 Identifikácia parametrov inverzného modelu.	145
3.50 Inverzné riadenie s priebežným učením, $u - q$	146
3.51 Inverzné riadenie s priebežným učením, $w - y$	146

3.52	Zapojenie s fixným stabilizačným regulátorom.	147
3.53	ANN adaptívne riadenie s referenčným modelom	148
3.54	Prediktívne riadenie na báze ANN.	149
3.55	Prediktívne riadenie na báze ANN s aproximáciou optimalizačného algoritmu. . .	150

ZOZNAM TABULIEK

2.1	Prehľad súvislostí medzi počtom vstupov a typom regulátora.	49
2.2	Vzťahy pre násobenie L-R fuzzy čísel.	56
2.3	Vzťahy pre delenie L-R fuzzy čísel.	56
3.1	Pravdivostná tabuľka funkcie OR.	83
3.2	Pravdivostná tabuľka funkcie XOR.	83
3.3	Body získané aplikáciou metódy klesajúceho gradientu.	92
3.4	Kódovanie čo trieda to neurón.	115
3.5	Klasické binárne kódovanie tromi bitmi.	116
3.6	Kódovanie číselnými hodnotami, jeden výstupný neurón.	116

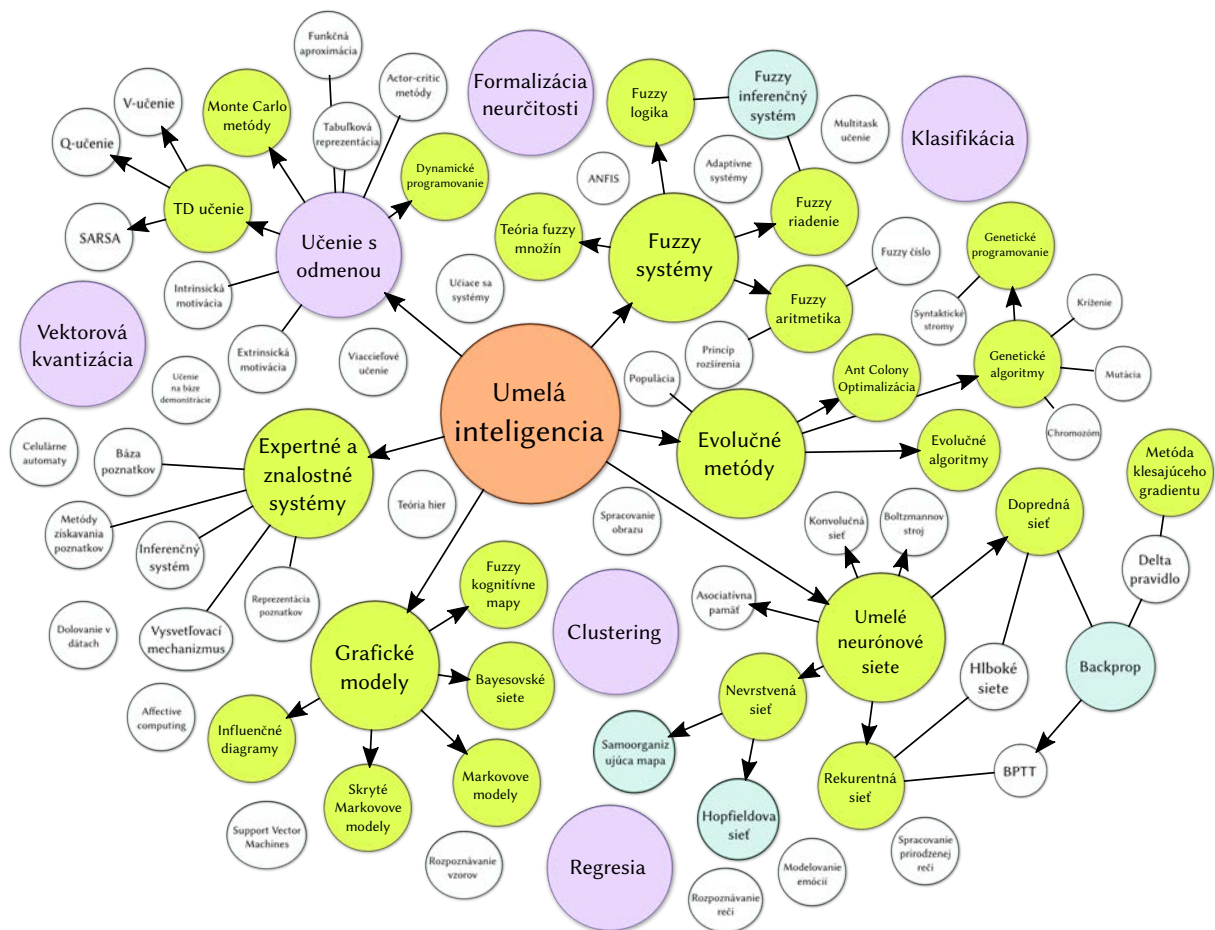
Táto kapitola prezentuje stručný úvod do základného názvoslovia z oblasti strojového učenia. Strojovým učením rozumieme súbor prístupov a metód, ktoré umožňujú strojom učiť sa, t.j. získať určité užitočné správanie bez toho, aby ho bolo potrebné explicitne naprogramovať. Zahrnieme tiež niektoré podporné metódy – napríklad užitočné formalizmy ako sú fuzzy prístupy, ktoré umožňujú formalizovať vágne pravidlá a výroky. Na tomto mieste zhrnieme predovšetkým základné pojmy spoločné pre všetky smery strojového učenia a jednak predstavíme prehľad vybraných smerov – ide predovšetkým o tie, ktorým sa podrobnejšie venujú nasledujúce kapitoly. Pre širší úvod však možno pozrieť aj iné zdroje – napr. [2, 1, 3]. Okrem toho sa priebežne budeme odkazovať na zdroje dotýkajúce sa jednotlivých konkrétnych tém.

Diagram na obrázku Obr. 1.1 ukazuje prehľad pojmov z oblasti strojového učenia a čiastočne ukazuje vzťahy medzi niektorými z nich, čím vzniká akási grafická ontológia pre oblasť umelej inteligencie. V žiadnom prípade nie je cieľom poskytnúť úplný prehľad – pri súčasnom obrovskom a neustále narastajúcom množstve znalostí z predmetnej oblasti sa dokonca zdá byť nemožné poskytnúť čitateľovi takýto prehľad. Sústreďujeme sa teda predovšetkým na metódy a prístupy, ktoré budú v ďalšom texte diskutované a na pojmy s nimi súvisiace.

Diagram môže poslúžiť čitateľovi ako mapa: možno dúfať, že sa pomocou nej bude ľahšie orientovať v obsahu nasledujúcich kapitol. Ako vidno, diagram zobrazuje nasledujúce základné oblasti:

- Fuzzy systémy – kapitola 2;
- Evolučné metódy ;
- Umelé neurónové siete – kapitola 3;
- Učenie s odmenou ;
- Grafické modely;
- Expertné a znalostné systémy – možno pozrieť napríklad v [1].

Skôr než by sme diskutovali jednotlivé prístupy, je ešte potrebné vysvetliť niektoré základné




Obr. 1.1: Strojové učenie – pojmy.

pojmy spoločné pre celú teóriu strojového učenia. Tejto úlohe venujme zvyšok kapitoly.

1.1 | Zovšeobecnenie

Jedným z kľúčových pojmov v teórii strojového učenia je pojem **zovšeobecnenie** (angl. generalization). Schopnosť zovšeobecňovať je vlastnosť učiaceho sa systému, ktorá určuje akým spôsobom a do akej miery je systém schopný na základe poznatkov nadobudnutých učeníím správne reagovať aj na také vstupy, o ktorých sa explicitne neučil. Zovšeobením teda myslíme schopnosť systému extrahovať z tréningových dát poznatky v takej forme, aby z nich bolo možné usudzovať aj o iných dátach, resp. o iných doteraz neznámych prípadoch.

Ako príklad možno uviesť regresiu: učiaci sa systém dostáva sadu dát reprezentujúcu určitú závislosť – t.j. určité vstupy a im zodpovedajúce požadované výstupy. Systém má potom za úlohu identifikovať o akú závislosť ide a vytvoriť regresný model, ktorý umožní výpočet výstupov aj pre iné vstupy než boli v pôvodnej tréningovej množine. V prípade, že systém správne zovšeobecňuje, vie aj tieto výstupy určiť správne (aspoň s určitou presnosťou). Ak nezovšeobecňuje správne,



Obr. 1.2: Je lokálne zovšeobecnenie postačujúce [4]?

výsledky budú chybné.

Iným príkladom môže byť rozpoznávanie vzorov vo vstupných dátach – napríklad rozpoznávanie obrazu alebo rozpoznávanie reči. Je zrejmé, že vstupný obraz, resp. rečová nahrávka nebudú v praktickej aplikácii totožné so vstupmi z tréningovej množiny – často sa budú líšiť výrazne. Odlišnosti môžu vzniknúť v dôsledku rušenia, zmeny podmienok – ako je úroveň osvetlenia, typ kamery, v prípade rozpoznávania reči typ mikrofónu, rečník, nálada, prostredie atď.

Okrem toho sa rozlišuje medzi dvomi základnými druhmi zovšeobecnenia [4]:

- *lokálne zovšeobecnenie*: týka sa stavov/vstupov, ktoré sú blízko seba v rámci nejakej metriky – napr. euklidovskej vzdialenosti;
- *nelokálne zovšeobecnenie*: týka sa stavov/vstupov, ktoré zdieľajú určitú spoločnú štruktúru.

Ako príklad možno uviesť mobilného agenta na Obr. 1.2, ktorý má za úlohu naučiť sa zatočiť doľava keď narazí v chodbe na zákrutu doľava [4]. Ak sa takýto agent naučí zatáčať v situácii, ktorú ukazuje ľavá časť obrázku, bude vedieť tieto poznatky použiť v podobnej situácii v pravej časti obrázku?

1.2 | Typy učenia: rozdelenie podľa typu úlohy

V teórii učenia sa pracuje s jednou základnou klasifikáciou metód učenia, ktorá jednotlivé metódy rozdeľuje podľa toho aký typ úlohy riešia. V zmysle tejto klasifikácie rozlišujeme nasledujúce typy učenia [5], [6]:

- **kontrolované učenie** (resp. učenie s učiteľom, angl. supervised learning, learning with a teacher);
- **učenie s odmenou** (angl. reinforcement learning);

- **nekontrolované učenie** (učenie sa bez učiteľa, angl. unsupervised learning, learning without a teacher);
- **čiastočne kontrolované učenie** (angl. semi-supervised learning).

Uvedme teraz krátku definíciu pre každý z týchto typov.

1.2.1 Kontrolované učenie

Charakteristickou vlastnosťou *kontrolovaného učenia* je, že učiaci sa systém dostáva spätnú väzbu. Systém dostáva na začiatku typicky takzvanú **tréningovú množinu dát**, ktorá sa skladá z dvojíc (*vstup, požadovaný výstup*). Keďže pre každý vstup je známy aj požadovaný výstup, možno jednoducho vypočítať nakoľko sa od neho odlišuje skutočný výstup učiaceho sa systému – t.j. možno určiť chybu.

Následne sa parametre systému nastavujú tak, aby chybu minimalizovali, čím dochádza k prenosu poznatkov obsiahnutých v dátach do štruktúry a parametrov systému, teda k učeniu. Hovoríme, že systém sa naučil tréningovú množinu.

Vlastnosti takéhoto učiaceho sa systému sa následne typicky testujú na tzv. **testovacej množine dát**, ktorá nie je podmnožinou tréningovej množiny, t.j. obsahuje také dáta, z ktorých sa systém neučil. Takto možno totiž otestovať či systém správne zovšeobecňuje.

Treba poznamenať, že tento typ učenia sa presnejšie označuje ako *učenie na báze korekcie chyby*. Takisto možno konštatovať, že v niektorej literatúre sa aj učenie s odmenou považuje za jeden z typov kontrolovaného učenia a nie za samostatnú kategóriu. Takémuto deleniu nechýba vnútorná logika, keďže učenie s odmenou, ako uvidíme, tiež operuje so spätnou väzbou, hoci v inej podobe. Rovnako však má zmysel – keďže učenie s odmenou a kontrolované učenie v zmysle učenia na báze korekcie chyby majú podstatne odlišné aplikácie – uvažovať ich ako dve osobitné kategórie. Ako vidno, aj my sa pridržame tejto konvencie.

Kontrolované učenie sa používa na riešenie radu úloh – azda najvýznamnejšie sú aplikácie na *regresiu* – t.j. systém dostane vstupy a výstupy pre nejakú funkčnú závislosť a má sa naučiť modelovať tú závislosť – a *klasifikáciu* – systém dostane vstupné vzory a do akej triedy patria a má sa naučiť priradiť triedu ku ľubovoľnému vstupnému vzoru.

Príklad klasifikácie je na Obr. 1.3. Ako vstup systém dostáva obrázok nejakého objektu – v tomto prípade ovocia. Úlohou je určiť o aký typ ovocia ide – priradiť ku vstupnému vzoru triedu. Obrázok ukazuje, že vstupný obrázok sa najprv transformuje na reprezentáciu vhodnú pre daný učiaci sa systém. Túto fázu nazývame *predspracovanie*. V rámci predspracovania sa vstupné dáta zároveň typicky – pokiaľ možno – transformujú do takej podoby, ktorá klasifikáciu uľahčí (napr. sa prevedú do frekvenčnej oblasti pomocou Fourierovej transformácie a pod.). Výstupom učiaceho sa systému je kód danej triedy.