

Obsah

1	Úvod	1
2	Čo je umelá inteligencia?	2
2.1	Umelá inteligencia a strojové učenie	3
3	Úlohy umelej inteligencie	3
4	Typy strojového učenia	4
4.1	Kontrolované učenie	4
4.2	Učenie s odmenou	5
4.3	Nekontrolované učenie	5
4.3.1	Zhlukovanie	6
4.3.2	Vektorová kvantizácia	7
4.3.3	Znižovanie rozmeru dát	7
4.3.4	Extrakcia hlavných charakteristík	7
5	Metódy umelej inteligencie	8
5.1	Porovnanie významnosti odvetví UI	10
6	Výber z existujúcich materiálov	15
6.1	Fuzzy prístupy	15
6.2	Umelé neurónové siete a hlboké učenie	16
6.3	Support vector machines	20
6.4	Metaheuristické optimalizačné metódy	21
6.5	Bayesovské siete	22
6.6	Markovovské a skryté markovovské modely	24
6.7	Rozhodovacie stromy a učenie na báze komisií	25
6.8	Metódy učenia s odmenou	27
6.9	Znalostné inžinierstvo a expertné systémy	29
6.10	Multiagentové systémy	29
6.11	Celulárne automaty	30
6.12	Zhlukovanie	34
6.13	Vyhodnocovanie úspešnosti učenia	35
7	Učebnice katedry KRIS	37
7.1	Kompendium	37
8	Záver	39

1 Úvod

Umelá inteligencia a strojové učenie predstavujú v súčasnosti sľubné, rapídne sa rozvíjajúce oblasti. Mnohí zahraniční zamestnávateľia začali tieto odvetvia považovať za akúsi novú matematiku – od absolventov spoločne so základnou teoretickou prípravou a praktickými zručnosťami, vyžadujú už často ako samozrejmosť aj základy z oblasti strojového učenia. Ten istý trend preniká postupne aj na slovenský pracovný trh, keďže mnoho slovenských firiem už tiež reflektuje veľký inovačný potenciál metód UI a začínajú ich integrovať do svojich výrobných a analytických systémov, služieb, ako aj do koncových produktov.

Osobitne silný je tento trend v oblasti priemyselných systémov, kde využitie metód umelej inteligencie a strojového učenia predpokladajú aktuálne dominantné paradigmy ako sú Industry 4.0 a internet vecí (IoT). Podobný vývoj však možno pozorovať aj v iných odvetviach – či už ide o inteligentné budovy, smart cities, inteligentné dopravné systémy, zdravotnícke systémy, o analýzu veľkých dát (big data) a pod. Aby bol náš pracovný trh schopný reagovať na tento vývoj, bude v budúcnosti potrebovať omnoho väčšie množstvo vysoko kvalifikovaných absolventov s kvalitnými základmi z oblasti umelej inteligencie a strojového učenia ako aj s dobrými všeobecnými zručnosťami z oblasti IT.

Katedra riadiacich a informačných systémov (KRIS) Elektrotechnickej fakulty Žilinskej univerzity v spolupráci s firmou Continental Matador Truck Tires s.r.o. vyvíja v rámci projektu KEGA 014ŽU-4/2018 viaceré aktivity, ktorých cieľom je napomôcť budovanie kvalitnej základne na prípravu takýchto kvalifikovaných odborníkov. Cieľom projektu je tiež lepšie previazať proces výučby s požiadavkami z praxe a tiež uľahčiť transfer pokrokových a inovatívnych metód umelej inteligencie a strojového učenia do praxe.

Jedným z viacerých čiastkových úsilí, ktorými sa tieto ciele majú dosiahnuť, je snaha vhodným spôsobom zmapovať aktuálny stav v oblasti umelej inteligencie a strojového učenia, poskytnúť prehľad o existujúcich úlohách a metódach umelej inteligencie, identifikovať dominantné oblasti a metódy, ako aj zhrnúť v skrátenej podobe niektoré zdroje, z ktorých možno čerpať informácie o nich.

Výsledný dokument má okrem toho slúžiť ako podkladový materiál ku vypracovaniu ďalších nadväzujúcich materiálov – predovšetkým nových študijných materiálov, ktorých vytvorenie predpokladá aktivita A1.4 a ktoré majú byť publikované vo forme vysokoškolskej učebnice.

Materiál obsiahnutý v tejto správe tak vlastne v sumárnej podobe dokumentuje vybrané výstupy nasledujúcich aktivít projektu:

A1.1 Exploratívna analýza oblastí UI.

Cieľom aktivity je exploratívna analýza oblastí umelej inteligencie, identifikácia hlavných metód, ktoré sa v rámci nich používajú a typov úloh, ktoré nimi možno riešiť.

Výstupy aktivity poslúžia ako obsah pri vypracovávaní nadväzných aktivít.

A1.2 Identifikácia dominantných oblastí a metód UI.

V rámci tejto aktivity sa budú identifikovať oblasti UI a ML, ktoré sú v súčasnosti najdominantnejšie, dochádza v nich ku najrapídnejšiemu vývoju a dosahujú sa v nich najsilnejšie výsledky. V rámci aktivity sa predpokladá úzka spolupráca s firmou Continental, aby sa zabezpečilo, že sa podarí úspešne identifikovať tie oblasti UI a ML, ktoré sú najrelevantnejšie z pohľadu požiadaviek z praxe.

A1.3 Zhromaždenie materiálov ku vybraným oblastiam UI.

Aktivita nadväzuje na výstupy aktivít A1.1 a A1.2. Pre identifikované dominantné oblasti UI a ML by sa v rámci tejto aktivity mali zhromaždiť existujúce materiály, ktoré bude možné použiť v rámci výučby. Dôležitými podmienkami sú predovšetkým: tematické zameranie, aktuálnosť a jazyková dostupnosť materiálov. Okrem toho sa identifikujú ďalšie oblasti, ktoré ešte nie sú dostatočne pokryté existujúcou literatúrou a inými materiálmi. Výstupom aktivity bude písomná správa o zistených skutočnostiach.

2 Čo je umelá inteligencia?

Ak budeme nižšie hovoriť o úlohách a metódach umelej inteligencie, žiadalo by sa na prvom mieste definovať, čo to vôbec umelá inteligencia je. Bolo by vhodné vysvetliť, čo všetko sa rozumie pod týmto pojmom a ozrejmiť, aký je rozdiel medzi systémami, ktoré sú „inteligentné“ a ktoré sú len „chytré“ (angl. smart), prípadne konvenčné. Definíciu umelej inteligencie by nebolo až také ťažké zaviesť, keby stačilo jednoducho povedať, že ide o inteligenciu, ktorou sa vyznačujú umelé systémy. Nanešťastie je taká definícia veľmi vágna, keďže nešpecifikuje, čo sa vlastne v tomto kontexte rozumie inteligenciou. Bolo by preto podľa nej nemožné rozlíšiť, ktoré umelé systémy sa majú považovať za inteligentné a ktoré nie.

V minulosti sa nanešťastie ukázalo, že definovať, čo to je inteligencia, je skutočne neľahká úloha, plná kontroverzných otázok. V dôsledku toho sa dodnes nepodarilo nájsť žiadnu definíciu umelej inteligencie, ktorá by bola konsenzuálne a všeobecne prijatá celou komunitou venujúcou sa tomuto odboru. Existuje dokonca niekoľko podstatne odlišných prístupov k tomu, ako umelú inteligenciu definovať. Štyri dominantné prístupy uvádza [1]. Umelá inteligencia by mala podľa nich byť charakterizovaná tým, že:

1. myslí tak ako človek;
2. myslí racionálne;
3. správa sa tak ako človek;
4. správa sa racionálne.

Tieto štyri prístupy sa teda diametrálne rozchádzajú v dvoch veciach: (a) či treba umelú inteligenciu definovať prostredníctvom toho, ako sa navonok správa, alebo podľa toho, ako vo vnútri funguje; (b) či treba za etalón inteligencie považovať človeka (vrátane emócií, afektívneho správania a pod.) alebo treba definície vzťahovať ku čistej racionalite.

Z uvedeného by malo byť zrejmé, že úloha definovať umelú inteligenciu nespadá čisto do kompetencie vedy, ale je do značnej miery skôr vecou filozofie (najväčším dielom zasahuje zrejme do filozofie mysle). Vzhľadom na tieto skutočnosti sa zdá, že nemá veľký zmysel pokúšať sa na tomto mieste špekulovať o tom, ktorá definícia umelej (a prirodzenej) inteligencie je presná a správna. Takisto sa nebudeme pokúšať jasnou hranicou oddeliť inteligentné systémy od neinteligentných. Pozornosť namiesto toho zameriame na konkrétne odvetvia, nástroje a metódy, ktoré v oblasti umelej inteligencie existujú, pokúsime sa identifikovať dominantné odvetvia a ku každému z nich priradiť niekoľko existujúcich zdrojov, z ktorých možno čerpať ďalšie poznatky. Takto môžeme dúfať, že si čitateľ sám induktívne vytvorí predstavu o tom, čo to umelá inteligencia je – bez toho, že by sme tento koncept museli striktno vymedziť ostrou definíciou.

2.1 Umelá inteligencia a strojové učenie

Jedným z kľúčových pojmov v oblasti umelej inteligencie je strojové učenie. Strojové učenie zahŕňa všetky metódy a prístupy, ktoré umožňujú umelým systémom nadobúdať poznatky, zručnosti, vylepšovať a inak modifikovať svoje správanie na základe skúseností a pod. Keďže ide o jednu z dominantných úloh umelej inteligencie, pojem strojové učenie sa niekedy nesprávne chápe ako synonymum pojmu umelá inteligencia. Je preto potrebné zdôrazniť, že význam oboch pojmov nie je rovnaký. Lepšie to uvidíme nižšie, keď predstavíme ďalšie odvetvia umelej inteligencie, ktoré priamo nesúvisia s učením.

3 Úlohy umelej inteligencie

Existuje veľké množstvo konkrétnych úloh, na ktorých riešenie je možné použiť metódy umelej inteligencie. Ide predovšetkým o také úlohy, ktoré nie je možné uspokojivo riešiť konvenčnými metódami. Na tomto mieste sa pokúsime vymenovať aspoň niekoľko dôležitých vysokoúrovňových kategórií, do ktorých možno tieto úlohy rozdeliť:

- **reprezentácia poznatkov** (vrátane neurčitých poznatkov, nepresných poznatkov, odvodzovania nových poznatkov a pod.);
 - kontrolované učenie,
 - nekontrolované učenie,
 - učenie s odmenou, ...
- **strojové učenie:**
- **optimalizácia** (spojitá, diskretná, lo-

- kálna, globálna, ...);
- **riadenie** s použitím prístupov UI;
- **plánovanie a rozvrhovanie**;
- **analýza dát** (inteligentné spracovanie dát, extrakcia príznakov, znižovanie rozmeru, predikcia, analýza zhukov, pokročilá vizualizácia, ...)

4 Typy strojového učenia

Keďže strojové učenie predstavuje jednu z dominantných oblastí umelej inteligencie, bude dobré jednotlivé typy strojového učenia charakterizovať aj podrobnejšie.

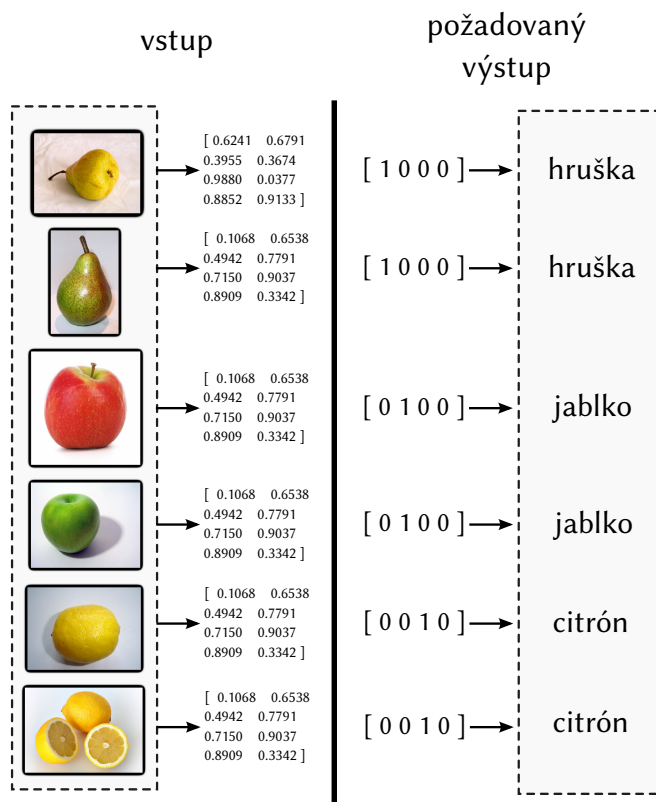
4.1 Kontrolované učenie

Charakteristickou vlastnosťou kontrolovaného učenia je, že učiaci sa systém dostáva spätnú väzbu. Systém dostáva na začiatku 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.

Kontrolované učenie sa používa na riešenie celého radu úloh. Najčastejšie ide o *regresné* alebo *klasifikačné* úlohy. Pri regresii systém dostane vstupy a výstupy získané z nejakej funkčnej závislosti a má za úlohu naučiť sa tú závislosť modelovať. Pôvodný systém vieme potom nahradiť získaným regresným modelom. Pri klasifikácii systém dostane vstupné vzory a informáciu o tom, do akej triedy patria. Cieľom je naučiť sa správne klasifikovať ľubovoľné ďalšie vstupné vzory – t.j. zatriediť ich do príslušnej triedy.

Príklad klasifikácie je na Obr. 1. Ako vstup systém dostáva obrázok nejakého objektu – v tomto prípade určitého druhu ovocia. Úlohou je určiť, o aký typ ovocia ide – t.j. priradiť ku vstupnému vzoru triedu. Obrázok ukazuje, že vstupný obraz 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.



Obr. 1: Kontrolované učenie – klasifikácia.

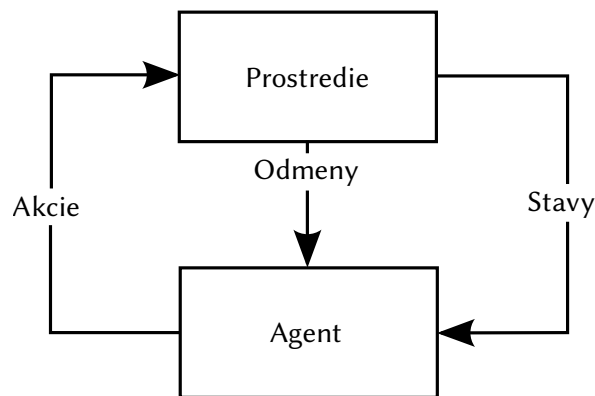
4.2 Učenie s odmenou

V prípade učenia s odmenou systém tiež dostáva spätnú väzbu. Táto má však iný charakter, než je to v prípade kontrolovaného učenia. Pre prezentované vstupy už nie sú známe požadované výstupy. Učiaci sa systém ako spätnú väzbu dostáva iba hodnotenie toho, ako dobre sa správa. Za korektné správanie dostáva systém odmenu. Za nekorektné správanie trest. Systém sa snaží hľadať takú stratégiu, ktorá by podľa možnosti maximalizovala odmeny.

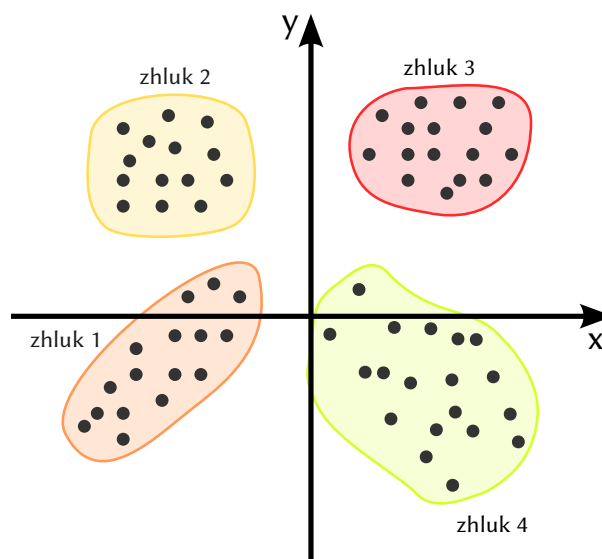
Príkladom úlohy, na ktorú možno tento typ učenia aplikovať, môže byť navigácia agenta v určitom prostredí, zbieranie a presúvanie objektov a pod. V prípade takýchto úloh nevieme väčšinou povedať, ako by mal učiaci sa systém v danej situácii presne reagovať, ale vieme jeho správanie ohodnotiť. Schematické znázornenie tohto princípu je na Obr. 2 – podrobnejšie sa k nemu vrátíme v neskoršej kapitole.

4.3 Nekontrolované učenie

Nekontrolované učenie je charakteristické tým, že v jeho prípade (na rozdiel od kontrolovaného učenia) neexistuje žiadna spätná väzba. Učenie je založené na princípoch samoorganizácie. Cieľom môže byť identifikovať v dátach zaujímavé závislosti a štruktúru [3]. Medzi úlohy tohto typu patrí napríklad zhľukovanie (tiež identifikácia zhľukov, zhľuková



Obr. 2: Učenie s odmenou: sekvenčné rozhodovanie [2].




Obr. 3: Identifikácia 4 zhlukov v dátach.

analýza, angl. clustering, cluster analysis), detekcia anomálií, extrakcia hlavných charakteristík, vektorová kvantizácia alebo znižovanie rozmeru dát [3, 4].

4.3.1 Zhlukovanie

Príklad zhukovania (angl. clustering) je na Obr. 3. Systému prezentujeme vstupné vektory (body) z 2-rozmerného priestoru. Systém má za úlohu vyhľadať v nich zhluky. Zhlukovanie (spoločne s ďalšími technikami – ako je znižovanie rozmeru dát a pod.) sa často vykonáva ako súčasť tzv. *exploratívnej analýzy dát*. Ide o počiatočnú fázu v dátovom inžinierstve, kedy získame novú dátovú množinu a snažíme sa oboznámiť so všeobecným charakterom dát a vybadať v nich určité závislosti a charakteristiky.



Obr. 4: Vektorová kvantizácia.

4.3.2 Vektorová kvantizácia

V prípade vektorovej kvantizácie má systém za úlohu diskretizovať spojitý vstupný priestor, presnejšie povedané nájsť čo najlepšiu diskretizáciu. Na vstupe systému sú vektory spojitých hodnôt. Výstupný priestor je diskrétny. Obsahuje len určitý počet referenčných vektorov, pričom každý vstupný vektor sa priradí ku niektorému z nich – napr. k tomu, ktorý je najbližšie podľa určitej metriky (napr. v zmysle euklidovskej vzdialenosti).

Existujú učiace sa systémy, ktoré sú schopné identifikovať vhodné referenčné vektory, prípadne ich adaptovať aj priebežne, počas samotnej kvantizácie. Ilustračný príklad ukazuje Obr. 4: kvantizujeme 2-rozmerné vektory. Ako vidno, oblasti, kde sa vyskytuje väčší počet vstupných vektorov, je snaha pokryť hustejšie – aby tam kvantizácia bola čo najpresnejšia.

4.3.3 Znižovanie rozmeru dát

Pri znižovaní rozmeru dát vstupné vektory transformujeme do priestoru nižšieho rozmeru než je rozmer pôvodného, vstupného priestoru. Systém sa má za úlohu naučiť také priradenie, pri ktorom dôjde k čo najmenej strate užitočnej informácie.

4.3.4 Extrakcia hlavných charakteristík

Pri extrakcii hlavných charakteristík má systém transformovať dáta do takej reprezentácie, ktorá vhodne vystihuje hlavné vlastnosti príslušných vstupných vektorov. Typicky to znamená znižovanie rozmeru dát ako v predchádzajúcom prípade.

5 Metódy umelej inteligencie

V oblasti umelej inteligencie existuje nepreberné množstvo metód a prístupov, ktoré sa snažia rozličnými spôsobmi riešiť vyššie vymenované úlohy. Je veľmi ťažké, azda až nemožné, poskytnúť vyčerpávajúci prehľad. Vymenujeme však aspoň niektoré dominantnejšie oblasti:

- **Fuzzy prístupy:** Reprezentácia vágnych poznatkov a operácie s nimi. Logická inferencia, vágne výpočty (fuzzy aritmetika), riadenie na báze lingvistických pravidiel (fuzzy riadenie), fuzzy algoritmy, fuzzy kognitívne mapy, ...
- **Umelé neurónové siete a hlboké učenie:** Kontrolované a nekontrolované učenie, učenie s odmenou, automatická extrakcia príznakov, schopnosť globálne zovšeobecňovať.
- **Support vector machines:** Kontrolované učenie založené na transformácii vzoriek do vysokorozmerného priestoru, kde budú pravdepodobne lineárne separovateľné; rozhodovacie hranice sa potom volia tak, aby sa maximalizoval jej odstup od vzoriek z rozdielnych tried.
- **Metaheuristické optimalizačné metódy:** Optimalizácia založená na metaheuristikách – často na evolučných prístupoch. Tieto metódy negarantujú nájdenie globálneho optima, ale ponúkajú prijateľné výsledky za prijateľný čas. Väčšinou operujú na populácii potencionálnych riešení.
- **Pravdepodobnostné grafické modely:** Modelovanie stochastických systémov, neurčitosti. Zahŕňajú najmä markovovské modely, skryté markovovské modely a bayesovské siete. Ale napr. aj klasifikácia: naivný bayesovský klasifikátor.
- **Rozhodovacie stromy:** Kontrolované učenie (klasifikácia, regresia).
- **Učenie na báze komisií:** Vytváranie komisií pozostávajúcich z viacerých modelov. Výsledok sa určuje hlasovaním, priemerovaním a pod.
- **Metódy učenia s odmenou:** Maximalizácia dlhodobého úžitku agentov vykonávajúcich úlohy sekvenčného rozhodovania.
- **Znalostné inžinierstvo a expertné systémy:** Práca so znalosťami, metódy ich získavania, metódy reprezentácie a práce s expertnými poznatkami.
- **Formálne logické systémy, predikátová logika, deskriptívna logika, ontológie, sémantické siete, ...:** Metódy umožňujúce rozličnými spôsobmi formalizovať znalosti a realizovať na základe nich logické odvodzovanie.

- **Plánovacie a rozvrhovacie metódy:** Riešia plánovacie a rozvrhovacie problémy (napr. automatické smerovanie vozidiel v logistickom systéme, tvorba rozvrhov a pod.).
- **Optimalizačné metódy:** Metódy spojitej optimalizácie (gradientné metódy, metódy vyššieho rádu, ...). Metódy diskkrétnej optimalizácie a spĺňania ohraničení (kombinatorické úlohy, programovanie ohraničení, celočíselné programovanie, lineárne programovanie, kvadratické programovanie, lokálne prehľadávanie okolia, ...). Riešenie zmiešaných optimalizačných problémov (s diskrétnymi aj spojitými premennými). Multikriteriálna optimalizácia.
- **Metódy prehľadávania stavového priestoru:** Riešenie zložitých úloh s diskrétnym stavovým priestorom. Využíva sa aj v niektorých plánovacích/rozvrhovacích metódach a diskrétnych optimalizačných metódach.
- **Metódy inteligentného riadenia:** Napr. prediktívne riadenie založené na učiacich sa modeloch, riadenie založené na učení s odmenou a pod.
- **Práca s prirodzeným jazykom a rečou:** Modelovanie jazyka, inteligentná korekcia pravopisu, pokročilé metódy užívateľského vstupu (napr. prediktívne klávesnice), strojový preklad, generovanie textu, sumarizácia textu a pod. Rozpoznávanie a syntéza reči.
- **Metódy dátovej analýzy:** Napr. predikcia, analýza zhlukov, predikcia časových radov, analýza textu a pod.
- **Metódy na znižovanie rozmeru dát, vizualizáciu vysokorozmerných dát:** napr. metóda PCA, autoenkodéry, t-SNE, largevis, UMAP a pod.
- **Multiagentové systémy:** Disciplína zaoberajúca sa špecificky otázkou interakcie (či už kooperatívnej alebo protivníckej) medzi viacerými agentmi – či už učiacimi sa alebo s pevne definovaným správaním.

Vo voľnom zmysle sem eventuálne môžeme zaradiť aj iné systémy, kde vzájomne interagujú jednoduchšie entity, ktoré v striktnom zmysle nie je možné považovať za agentov. Príkladom môžu byť **celulárne automaty** – hoci bunky celulárneho automatu ťažko možno považovať za agentov, celulárne automaty sú predsa len charakteristické podobnými vlastnosťami ako multiagentové systémy – napr. emergenciou zložitého správania z pomerne jednoduchých čiastkových správání jednotlivých entít.

5.1 Porovnanie významnosti odvetví UI

Nie je ľahké objektívnym spôsobom zachytiť vývojové trendy v oblasti umelej inteligencie, posúdiť relatívny význam rozličných odvetví v tejto oblasti, odhadnúť, ktoré metódy sa aktívne rozvíjajú a ktoré naopak strácajú na význame. Hodnotenia jednotlivých odborníkov budú nevyhnutne do značnej miery subjektívne a pravdepodobne sa budú aj dosť rozchádzať – podľa toho, do akej komunity odborníci patria, akým zdrojom sú najviac exponovaní a podobne.

Aby sme pohľad na jednotlivé odvetvia aspoň čiastočne objektivizovali, vyťažili sme o nich dáta a sformulovali sme na základe nich niekoľko kritérií. Sledovali sme – prostredníctvom vybraných kľúčových fráz – počet zmienok o nich za obdobie od roka 2016 do súčasnosti, a to v rámci nasledujúcich portálov:

- Scopus,
- GitHub,
- Reddit,
- StackOverflow.

V prípade portálov Reddit a StackOverflow sa dolovanie robilo pomocou vyhľadávania cez Google – s použitím parametra „site“. V prípade platformy GitHub sme spočítavali existujúce repozitáre vyhovujúce daným kľúčovým frázam a požadovali sme, aby posledná aktualizácia repozitára bola v roku 2016 alebo neskôr.

Vzhľadom na to, že vyhľadávanie v rámci platformy GitHub podporuje použitie najviac 5 logických operátorov, použilo sa v jej prípade len prvých 6 kľúčových fráz. Aby sme tento nedostatok aspoň čiastočne kompenzovali, vyhľadali sme kľúčové frázy aj prostredníctvom vyhľadávača Google s príslušným „site“ nastavením a výsledky z oboch typov vyhľadávaní sme sčítali dokopy.


Výsledky z jednotlivých behov sme normalizovali tak, aby súčet pre každé kritérium (platformu) bol 100. Následne sme priemerovaním a kumuláciou výsledkov získali sumárny graf, ktorý ukazuje Obr. 5. Keďže výsledky podľa jednotlivých kritérií sa najprv normalizovali, každé kritérium má pri hodnotení rovnakú váhu. Kľúčové frázy, ktoré sme pri vyhľadávaní použili, sú zhrnuté v Tab. 1.

Vizualizovať sme sa pokúsili aj relatívnu dôležitosť kľúčových fráz samých osebe – počtom výskytov v rámci platformy Google Scholar: opäť za obdobie od roka 2016. Výsledkom je mračno tagov (angl. tagcloud) na Obr. 6, kde relatívna dôležitosť pojmov je vizualizovaná veľkosťou fontu a farebne.

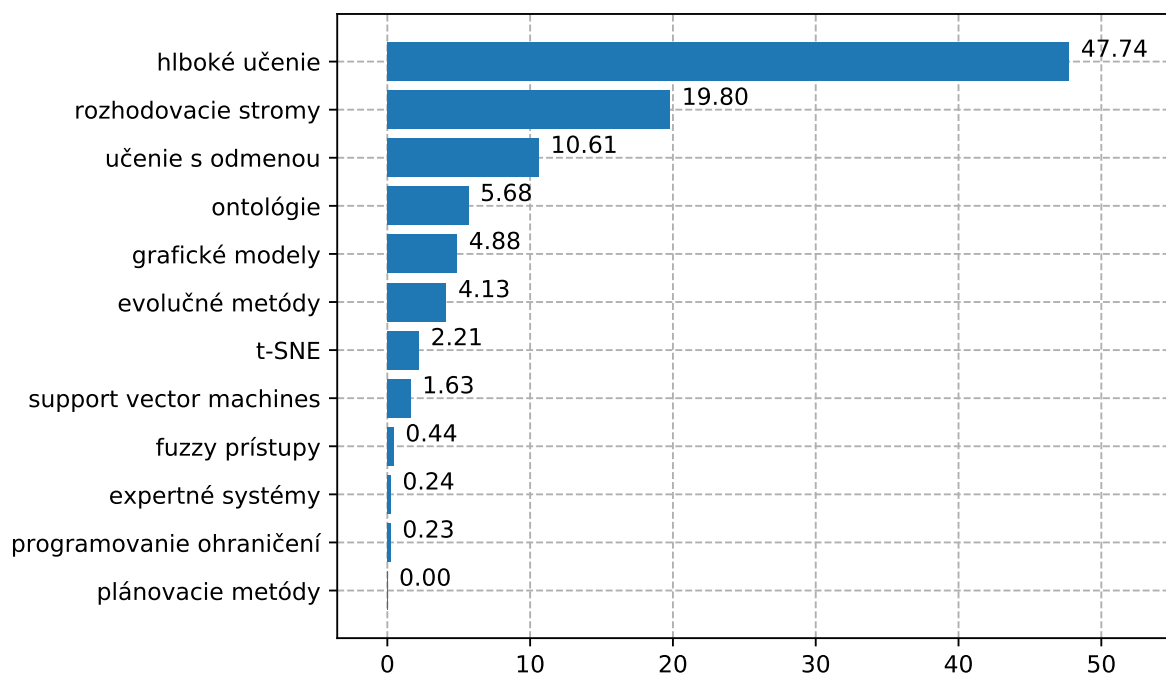
Kvôli lepšej prehľadnosti uvedieme nakoniec relatívnu významnosť aj podľa jednotlivých kritérií osobitne. Výsledky vidno na Obr. 7, Obr. 8, Obr. 9, Obr. 10.

Tab. 1: Kľúčové frázy použité pre jednotlivé oblasti UI.

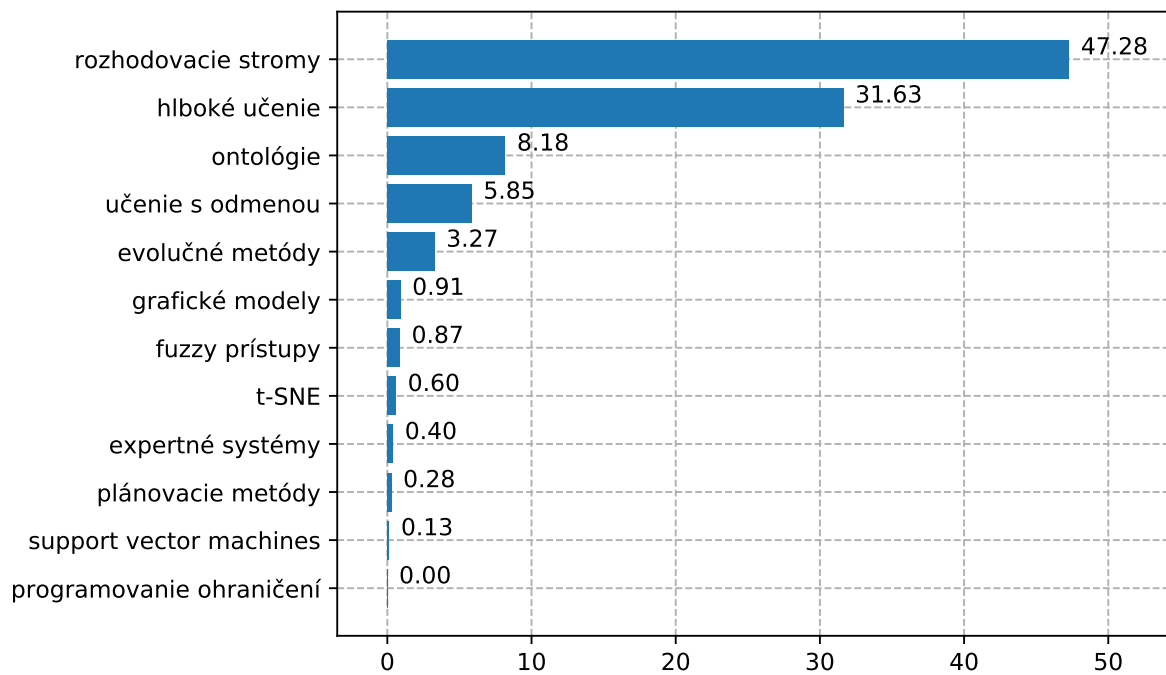
oblasť UI	kľúčové frázy
hlboké učenie	"deep learning", "artificial neural network", "convolutional network", "autoencoder", "generative adversarial network"
evolučné metódy	"evolutionary method", "genetic algorithm", "genetic programming", "particle swarm optimization", "differential evolution", "swarm intelligence", "evolutionary strategy", "ant colony optimization"
fuzzy prístupy	"fuzzy control", "fuzzy controller", "fuzzy arithmetic", "fuzzy logic"
support vector machines	"support vector machine"
grafické modely	"probabilistic graphical model", "bayes network", "markov model", "bayesian network", "naive bayes"
rozhodovacie stromy	"decision tree", "C4.5", "C5", "random forest", "xgboost"
expertné systémy	"expert system"
programovanie ohraňení	"constraint programming", "gecode", "minizinc"
t-SNE	"t-SNE", "tsne"
ontológie	"ontology", "ontologies"
učenie s odmenou	"reinforcement learning", "SARSA", "TD learning", "DQN", "imitation learning"
plánovacie metódy	"planning method", "planning methods", "PDDL", "RDDL", "planning problem", "planning algorithm"




Obr. 7: Porovnanie významnosti oblastí UI a ML podľa kritéria Scopus.



Obr. 8: Porovnanie významnosti oblastí UI a ML podľa kritéria GitHub.



Obr. 9: Porovnanie významnosti oblastí UI a ML podľa kritéria Reddit.



Obr. 10: Porovnanie významnosti oblastí UI a ML podľa kritéria StackOverflow.

6 Výber z existujúcich materiálov

Ďalej sa pokúsime aspoň ku niektorým vybraným oblastiam a metódam UI poskytnúť stručný prehľad existujúcich zdrojov. Nepôjde nám o poskytnutie vyčerpávajúceho prehľadu – budeme sa len snažiť vymenovať niekoľko užitočných zdrojov, z ktorých možno čerpať relevantné informáciu o danej téme.

6.1 Fuzzy prístupy

Z literatúry venujúcej sa fuzzy prístupom môžeme spomenúť napr.:

- SPALEK, J. – JANOTA, A. – BALAŽOVIČOVÁ, M. – PŘIBYL, P. *Rozhodovanie a riadenie s podporou umelej inteligencie*. Žilinská univerzita v Žiline/EDIS, 2005. ISBN 80-8070-354-X.

Obsahuje dobrý úvod do fuzzy systémov, teóriu fuzzy množín, fuzzy logiku, fuzzy entropiu, adaptívny neuro-fuzzy inferenčný systém (ANFIS) a ďalšie témy. Výhodou je aj jazyková dostupnosť.

- GREGOR, M. *Umelá inteligencia 1*. Žilina: CEIT, a.s., 2014. ISBN 978-80-971684-1-4.
Obsahuje úvod do problematiky fuzzy systémov, vrátane fuzzy logiky, fuzzy riadenia a fuzzy aritmetiky. Výhodou je jazyková dostupnosť.
- ROSS, T. J. *Fuzzy Logic with Engineering Applications*. John Wiley & Sons, 2004, second edition ed. ISBN 0-470-86075-8.

Témy: teória fuzzy množín; výhody a obmedzenia fuzzy systémov; klasické relácie a fuzzy relácie; charakteristiky fuzzy množín; fuzzy logika; automatické metódy návrhu fuzzy systémov (najmenšie štvorce, gradientné metódy, clustering, ...); fuzzy asociatívne pamäte; redukcia pravidiel; rozhodovanie s fuzzy informáciami; fuzzy Bayesovské rozhodovacie modely; viaccieľové rozhodovanie; fuzzy klasifikácia a rozpoznávanie vzorov; fuzzy aritmetika; fuzzy riadenie; fuzzy kognitívne mapy; fuzzy optimalizácia; fuzzy lineárna regresia; vierohodnosť; plauzibilita.

- HANSS, M. *Applied Fuzzy Arithmetic: An Introduction with Engineering Applications*. 2005. Springer, Berlin, 2005. ISBN 3-540-24201-5.

Témy: teória fuzzy množín; elementárna fuzzy aritmetika (fuzzy čísla, aritmetické operácie v diskretnej, L-R a rozloženej reprezentácii); štandardná fuzzy aritmetika; pokročilé metódy – transformácie; spracovanie neurčitosti vo fuzzy aritmetike; inverzná fuzzy aritmetika; aplikácie v strojárstve, riadení, biomedicíne, geotechnike.

Z užitočných softvérových nástrojov môžeme spomenúť napr.:

- **Fuzzy Logic Toolbox; Matlab**, closed-source.

Obsahuje implementáciu Mamdaniho inferenčného systému – operátory (AND, OR, implikácia, agregácia, defuzzifikácia) a tvary funkcií príslušnosti možno nastaviť, takže je možné nakonfigurovať aj inferenciu iných typov. Obsahuje aj inferenčný systém typu Takagi-Sugeno. Súčasťou toolbox-u sú bloky pre Simulink. Okrem toho implementuje základné fuzzy aritmetické operácie.

- **Fuzzylite; C++/Java**, Apache License 2.0.

Zrejme najznámejšia voľne dostupná implementácia fuzzy logiky pre C++. Disponuje aj grafickým nástrojom na návrhu fuzzy inferenčných systémov a podporuje viacero súborových formátov – vrátane formátu, ktorý používa Fuzzy Logic Toolbox v Matlab-e.

Od verzie 5 sa licencia knižnice zmenila na LGPL. Grafické rozhranie má od tejto verzie komerčnú proprietárnu licenciu a jeho kód je uzavretý. Staršia verzia je však stále k dispozícii.

6.2 Umelé neurónové siete a hlboké učenie

Z literatúry týkajúcej sa umelých neurónových sietí a hlbokého učenia môžeme spomenúť:

- GOODFELLOW, I. – BENGIO, Y. – COURVILLE, A. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.

Obsažná a aktuálna publikácia o hlbokom učení od autorov, ktorí patria medzi špičky v odbore. Obsahuje aj všeobecný úvod do lineárnej algebry a strojového učenia. Predstavuje základy umelých neurónových sietí a hlbokého učenia a prezentuje súčasné najlepšie praktiky. Samozrejme sa zaoberá aj konvolučnými a rekurentnými architektúrami.

- BENGIO, Y. *Practical recommendations for gradient-based training of deep architectures*. In *Neural Networks: Tricks of the Trade*, pp. 437–478. Springer, 2012.

Prezentuje praktické odporúčania týkajúce sa gradientného učenia v hlbokých neurónových sieťach. Viacero uvedených prístupov však platí aj pre plytké architektúry.

- GREGOR, M. – NEMEC, D. – HRUBOŠ, M. – SPALEK, J. *Umelá inteligencia 2: Hlboké učenie*. CEIT, a.s., 2017. ISBN 978-80-89865-03-1.

Obsahuje pomerne rozsiahly úvod do problematiky umelých neurónových sietí a hlbokého učenia, vrátane konvolučných sietí a ich použitia na spracovanie obrazu, kapitolách o rekurentných sieťach, autoenkodéroch, protivníckych príkladoch a ďalších

témach súvisiacich s umelými neurónovými sieťami a hlbokým učením. Súčasťou učebnice sú jednoduché ilustračné príklady so zdrojovými kódmi v jazyky Python. Výhodou učebnice je jazyková dostupnosť.

Online je dispozícii aj väčší počet kurzov, z ktorých spomenieme aspoň nasledujúce:

- Na portáli [Coursera](#) je k dispozícii špecializácia na tému hlboké učenie, ktorá pozostáva z viacerých kurzov. Vyučujúcim je známy expert na strojové učenie a metódy umelej inteligencie Andrew Ng. Kurz obsahuje pozvoľný úvod a je dosť podrobný. Obsahuje aj praktické príklady. Videá sú k dispozícii aj bezplatne – prostredníctvom oficiálneho [YouTube kanála Deeplearning.ai](#).
- Na portáli [Udacity](#) je k dispozícii kurz [Deep Learning](#) od Google. Obsahuje pomerne jednoduchý vysokoúrovňový úvod do problematiky hlbokého učenia doplnený praktickými príkladmi a cvičeniami pre nástroj [tensorflow](#).
- Na portáli [Coursera](#) je k dispozícii kurz [Neural Networks for Machine Learning](#) od prof. Geoffrey Hinton, jedného zo špičkových odborníkov na umelé neurónové siete, ktorý pôsobí na University of Toronto a v súčasnosti paralelne pracuje aj na výskume pre spoločnosť Google. Keďže kurz je z roku 2012, najaktuálnejšie poznatky v ňom už nie sú zahrnuté.
- Na tom istom portáli je k dispozícii aj kurz Andrewa Ng – profesora z University of Stanford a zakladateľa projektu Google Brain – na tému [Machine Learning](#), ktorý tiež zahŕňa prednášky o umelých neurónových sieťach. Keďže kurz je z roku 2012, najaktuálnejšie poznatky v ňom už tiež nie sú zahrnuté.

Za zmienku stoja aj niektoré online návody:

- Úvodné návody (1, 2) pre balíček keras.
- [Príklady](#) pre balíček keras: napr. klasifikácia, konvolučné siete, optické rozpoznávanie znakov, rekurentné siete, neuromalby, variačné autoenkodéry, ...
- [Návod na regresiu](#) pomocou balíčka keras.
- Veľmi známy a obľúbený [blog Christophera Olaha](#) o LSTM vrstvách.
- Známy [blog](#) Andreja Karpathy o rekurentných neurónových sieťach a modelovaní jazyka (The Unreasonable Effectiveness of Recurrent Neural Networks; char-rnn).
- [Rozpoznávanie dopravných značiek](#) pomocou nástroja Tensorflow.
- Článok o metóde [word2vec](#) v nástroji Tensorflow.

- [Návod na rozpoznávanie reči](#) pomocou nástroja Tensorflow.
- [Návod a príklady](#) pre nástroj PyTorch.

Existuje nepreberné množstvo softvérových nástrojov pre umelé neurónové siete. Patria sem napríklad nasledujúce:

- **Keras; Python**, MIT licencia.

Vysokourovňový, ale flexibilný nástroj na zostavovanie umelých neurónových sietí rozličných architektúr – vrátane moderných konvolučných sietí, rekurentných sietí a pod. Výhodou je, že má pomerne čisté API rozhranie, jednoducho sa používa a veľmi aktívne sa vyvíja. V dôsledku toho dochádza ku rýchlemu transferu nových prístupov a metód do jeho kódu.

Na spodnej úrovni je schopný pracovať nad nástrojmi tensorflow, theano, CNTK a postupne mu pribúda podpora aj pre ďalšie nástroje.

- **Tensorflow; C++/Python/Java/Go**, Apache licencia.

Nízkoúrovňový nástroj vyvíjaný spoločnosťou Google, ktorá ho aj interne používa. Umožňuje realizovať numerické výpočty s mnohorozmernými poľami na základe grafov dátových tokov. Výpočty vie realizovať na procesore alebo na grafických kartách. Obsahuje základné stavebné bloky pre moderné umelé neurónové siete. Teší sa v súčasnosti značnej popularite a podlieha aktívnemu vývoju.

- **Torch; Lua**, BSD licencia.

Nástroj Torch je ďalšou z radu knižníc, ktoré implementujú operácie s mnohorozmernými poľami a obsahujú potrebné stavebné prvky pre konštrukciu neurónových sietí. Jedným z kľúčových cieľov vývojárov je flexibilita. Nástroj sa v komunite teší určitej popularite – medzi dôvody môže patriť fakt, že išlo o jednu z prvých knižníc, ktoré boli k dispozícii v dobe, keď došlo ku prelomovým objavom v oblasti hlbokého učenia.

Nástroj Torch v súčasnosti intenzívne používa napríklad spoločnosť Facebook. Jeho miernou nevýhodou je, že je napísaný v skriptovacom jazyku Lua, ktorý sa inak v oblasti strojového učenia veľkej popularite neteší. Môže byť preto o čosi náročnejšie integrovať kód vytvorený pre túto platformu s inými aplikáciami z oblasti strojového učenia.

- **PyTorch; Python**, BSD licencia.

Nástroj PyTorch je odpoveďou na nevýhody spojené s implementáciou nástroja Torch v jazyku Lua. PyTorch je verzia nástroja Torch pre jazyk Python. Hoci sa objavila

pomerne nedávno – omnoho neskôr než nástroje Tensorflow, Torch alebo CNTK –, veľmi rýchlo sa vytvorila komunita vývojárov, ktorá s ním pracuje. Je možné, že jeho popularita časom dobehne alebo predstihne aj nástroj Tensorflow.

Hlavný rozdiel medzi týmito dvomi nástrojmi spočíva v tom, že v nástroji Tensorflow (a v mnohých ďalších nástrojoch) sú grafy dátových tokov statické. Musia sa najprv celé vytvoriť a až potom sa spustia. Oproti tomu nástroj PyTorch je omnoho imperatívnejší – grafy sa tvoria dynamicky, čo je výhodné najmä pri implementácii rekurentných sietí s dynamickými dĺžkami postupností a pod. Na druhej strane to môže sťažovať optimalizáciu grafov. Možno spomenúť, že aj v najnovších verziách (v čase písania textu) nástroja Tensorflow je snaha o podporu imperatívneho prístupu – ale ako doplnku ku klasickým statickým grafom.

- **CNTK; CFG/C++/Python/Java/C#**, MIT licencia.

CNTK je nízkoúrovňový nástroj pre hlboké učenie vyvíjaný spoločnosťou Microsoft. V súčasnosti sa distribuuje pod alternatívnym názvom „Microsoft Cognitive Toolkit“. Jadro nástroja je v jazyku C++ a podobne ako ďalšie nástroje umožňuje pracovať s procesorom aj s grafickými kartami. Spočiatku sa s ním interagovalo výhradne prostredníctvom konfiguračných súborov, ale v novších verziách pribudli API rozhrania pre C++, Python a ďalšie jazyky. Takisto sa dá použiť spolu s vysokoúrovňovým balíčkom Keras.

- **Caffe; CFG/C++/Python**, BSD licencia.

Nástroj vyvíjaný University of California, Berkeley. Jadro nástroja je v C++. Štandardný spôsob interakcie s nástrojom je prostredníctvom konfiguračných súborov. Existuje aj rozhranie pre Python. Nevýhodou je podstatne komplikovanejšia inštalácia, než majú ostatné nástroje.

Zaujímavá je tzv. modelová zoo, ktorá obsahuje veľký počet sietí natrénovaných pomocou Caffe. Viacero z predtrénovaných modelov sa používa aj v iných nástrojoch – samozrejme potom, ako boli skonvertované do príslušného formátu.

- **Neural Network Toolbox; Matlab**, komerčná licencia.

Obsahuje implementáciu pomerne širokej škály architektúr a metód učenia. V novších verziách obsahuje aj implementáciu konvolučných sietí. Navyše obsahuje bloky pre Simulink a niekoľko typov regulátorov založených na ANN.

V čase písania textu má najaktuálnejšia verzia prostredia Matlab označenie 2018a. Staršie verzie (< 2017b) prostredia neimplementovali takmer žiadne aktuálne používané prístupy a architektúry, pretože vždy viacero rokov zaostávali za súčasným

vývojom. Aktuálna verzia je na tom o niečo lepšie – umožňuje zostavovať siete s flexibilnejšími architektúrami, dopĺňa podporu pre niektoré často používané bloky ako je napr. dávková normalizácia a má podporu pre realizáciu výpočtov na grafickej karte.

6.3 Support vector machines

Support vector machines predstavuje v strojovom učení jeden z obľúbených prístupov ku realizácii klasifikácie a regresie, preto sa mu venuje viacero publikácií z oblasti strojového učenia a dátovej analýzy, napr.:

- HASTIE, T. – TIBSHIRANI, R. – FRIEDMAN, J. *The Elements of Statistical Learning*. Springer, 2009, second edition. ISBN 978-0-387-84858-7.

Publikácia poskytujúca širší prehľad o metódach strojového učenia, kde jedna z kapitol je venovaná support vector machines.

- HAN, J. – PEI, J. – KAMBER, M. *Data Mining: Concepts and Techniques*. Elsevier, 2012. ISBN 978-0-12-381479-1.

Publikácia venujúca sa dolovaniu v dátach, vrátane ich predspracovania, exploratívnej analýzy, základov štatistiky, návrhu dátových centier, dolovania vzorov, klasifikácie, zhlukovania a ďalších techník. Support vector machine sa venuje kapitola o pokročilých metódach klasifikácie.

- BOSWELL, D. *Introduction to Support Vector Machines*. 2002. URL: <dustwell.com/PastWork/IntroToSVM.pdf>.

Stručný 15-stranový úvod do problematiky support vector machines. Výhodou je, že ide o samostatný elektronický, voľne dostupný materiál, ktorý sa venuje špecificky téme support vector machines.

Z online kurzov, kde sa support vector machines preberajú môžeme spomenúť napr. kurz Andrewa Ng o strojovom učení s názvom [Machine Learning](#), ktorý poskytuje portál [Coursera](#).

Z nástrojov môžeme spomenúť napríklad nasledujúce knižnice:

- **LibSVM**; C++/Java, BSD License.

Jedna z najznámejších knižníc pre support vector machines. Okrem C++ a Javy má aj rozhrania pre jazyky Python, R, MATLAB, Perl, Ruby, Weka, Common LISP, CLISP, Haskell, OCaml, LabVIEW a PHP. Využívajú ju aj viaceré grafické nástroje, napr. RapidMiner.

- **Scikit-learn; Python**, BSD licencia.

Pythonový balíček Scikit-learn obsahuje implementáciu viacerých druhov support vector machines, podporujúcich klasifikáciu aj regresiu.

6.4 Metaheuristické optimalizačné metódy

Z literatúry týkajúcej sa metaheuristických optimalizačných metód – predovšetkým evolučných metód – vyšlo viacero dobrých titulov v češtine. Samozrejme tiež existuje rozsiahla literatúra v anglickom jazyku:

- HYNEK, J. *Genetické algoritmy a genetické programovanie*. Praha: Grada Publishing, a.s., 2008. ISBN 978-80-7300-218-3.

Táto učebnica je vhodná ako dobrý úvodný text. Výhodou je aj jazyková dostupnosť. Zaoberá sa genetickými algoritmi a genetickým programovaním.

- ZELINKA, I. – OPLATKOVÁ, Z. – ŠEDA, M. – OŠMERA, P. – VČELAŘ, F. *Evoluční výpočetní techniky: Principy a aplikace*. Praha: BEN – technická literatura, 2009. ISBN 978-80-7300-218-3.

Ďalšia učebnica venujúca sa evolučným technikám v češtine. Zameranie je širšie – nielen na genetické algoritmy. Učebnica obsahuje aj úvod do teórie grafov a pod.

- HAUPT, R. L. – HAUPT, S. E. *Practical genetic algorithms*. John Wiley & Sons, 2004. ISBN 0-471-45565-2.

Dobrý praktický materiál o genetických algoritmoch a genetickom programovaní. Obsahuje ukážky kódu pre Matlab a Fortran a dopĺňujúcu kapitolu o optimalizácii na báze mravčích kolónií (ant colony optimization), simulovanom žíhaní (simulated annealing), optimalizácii na báze rojenia častíc particle swarm optimization, evolučných stratégiách, atď.

- POLI, R. – LANGDON, W. B. – MCPHEE, N. F. – KOZA, J. R. *A field guide to genetic programming*. Lulu. com, 2008. ISBN 978-1-4092-0073-4. URL: <<http://www.gp-field-guide.org.uk>>.

Dobrá praktická príručka. Obsahuje odkazy na ďalšie zdroje a informácie o Java knižnici TinyGP vyvinutej autormi.

- MITCHELL, M. *An Introduction to Genetic Algorithms*. Cambridge, Massachusetts: MIT Press, 1999. ISBN 0-262-13316-4.

Obsahuje základnú teóriu ku genetickým algoritmom. Jedna kapitola sa venuje škálovaniu hodnotiacich funkcií.

systémov (po konverzii stromov poruchových stavov do bayesovských sietí). Influenčné diagramy sú aplikačne predstavené pri analýze rizík cestných tunelov. Výhodou je aj jazyková dostupnosť.

- DARWICHE, A. *Modeling and Reasoning with Bayesian Networks*. Cambridge University Press, 2009. ISBN 978-0-511-50152-4.

Obsahuje úvod do formálnych základov a praktických aplikácií bayesovských sietí. Predstavuje techniky tvorby bayesovských sietí – techniky na syntézu modelov od návrhu, učenia z dát a po ladenie modelov s použitím analýzy citlivosti; algoritmy presnej a približnej inferencie, a to na teoretickej aj praktickej úrovni. Autor predpokladá obmedzené množstvo znalostí o jednotlivých konceptoch na strane čitateľa a metódou krok za krokom ho oboznamuje s jednotlivými konceptmi.

Z online kurzov venovaných bayesovským sieťam môžeme spomenúť napríklad známy kurz [Probabilistic Graphical Models Specialization](#). Kurz je v súčasnosti realizovaný v rámci platformy [coursera.org](#) ako špecializácia pozostávajúca z viacerých osobitných online kurzov. Prednášajúcou je známa odborníčka zo Stanford University Daphne Koller. Kurz sa venuje všeobecne pravdepodobnostným grafickým modelom: t.j. okrem bayesovských sietí sa zaoberá aj markovovskými a skrytými markovovskými modelmi.

Existuje tiež viacero softvérových nástrojov, ktoré umožňujú konštruovať bayesovské siete a pracovať s nimi. Známe sú napríklad nasledujúce nástroje:

- **Hugin Developer**; komerčná licencia.

Jeden z najznámejších nástrojov. Okrem klasických bayesovských sietí umožňuje konštruovať aj influenčné siete zahŕňajúce rozhodovacie uzly a pod. Poskytuje API rozhrania pre C, C++, Javu, .NET a ďalšie. Podporuje učenie sa z dát.

- **Netica**; komerčná licencia.

Podporuje učenie sa z dát. Má API rozhrania pre jazyky Java, C, C++, C# a Visual Basic. Priamo z bayesovských modelov je možné generovať webové rozhrania.

- **MSBNx; COM modul** pre Windows, komerčná licencia.

COM modul pre operačný systém Windows obsahujúci implementáciu bayesovských sietí a iných pravdepodobnostných grafických modelov ako sú napr. skryté Markovove modely.

- **Bayes Net Toolbox for Matlab**; prostredie **Matlab**, LGPL v.2.

Toolbox implementujúci bayesovské siete pre nástroj Matlab. Podporuje statické aj dynamické bayesovské siete, vrátane učenia. Zdá sa, že jeho vývoj v súčasnosti ak-

tívne nepokračuje, posledná verzia toolboxu je však k dispozícii prostredníctvom GitHub repozitára.

- **Tetrad; Java**, GPL v.2.

Otvorený nástroj na učenie sa a prácu s bayesovskými sieťami napísaný v jazyku Java.

- **SamIam**.

Javový nástroj na učenie sa a prácu s bayesovskými sieťami vyvinutý na University of California, Los Angeles.

- **Bnlearn; jazyk R**, licencia GPL-2/GPL-3.

Balíček pre jazyk R, ktorý umožňuje konštrukciu bayesovských sietí aj učenie sa z dát. Existujú aj dve knižné publikácie, ktoré sa mu venujú.

- **Libpgm; Python**, New BSD License.

Balíček pre bayesovské siete, podporujúci aj učenie z dát, vrátane učenia sa štruktúry siete. Podporuje diskkrétne a lineárne gaussovské bayesovské siete. Zdá sa, že knižnica sa už aktívne nevyvíja.

- **Pomegranate; Python**, MIT License.

Balíček podporujúci prácu s bayesovským a naivným bayesovským klasifikátorom, markovovskými reťazcami a skrytými markovovými modelmi a predovšetkým s diskrétnymi bayesovskými sieťami.

- **Edward; Python**, Apache Licence v. 2.0.

Balíček implementujúci bayesovské prístupy a variačnú inferenciu v jazyku Python pomocou nástroja tensorflow. Pomocou nástroja je možné vytvárať niektoré typy bayesovských sietí, ale napríklad aj bayesovské neurónové siete.

- **PyMC3; Python**, Apache Licence v.2.0.

Balíček pre bayesovské štatistické modely a pravdepodobnostné strojové učenie. Podporuje variačnú inferenciu. Umožňuje konštruovať bayesovské siete, veľmi flexibilným, hoci dosť nízkoúrovňovým spôsobom (vrcholy grafu sa definujú priamo ako rozdelenia pravdepodobnosti príslušného typu).

6.6 Markovovské a skryté markovovské modely

Z literatúry týkajúcej sa markovovských a skrytých markovovským modelov môžeme spomenúť napr. nasledujúce tituly:

- KOLLER, D. – FRIEDMAN, N. *Probabilistic Graphical Models: Principles and Techniques*. MIT press, 2009. ISBN 978-0262013192.

Rozsiahla publikácia venujúca sa orientovaným aj neorientovaným grafickým modelom. Obsahuje aj state o učení sa markovovských a skrytých markovovských modelov a mnohých ďalších pokročilých témach.

- ROSS, S. M. *Introduction to Probability Models*. Academic Press, 2014, eleventh edition. ISBN 978-0-12-407948-9.

Publikácia začínajúca od základov teórie pravdepodobnosti a venujúca sa markovovským reťazcom s diskretným a spojitým časom. Autor následne rozoberá aj viaceré nadstavbové témy ako sú teória tvorby radov, teória spoľahlivosti a pod.

Online kurz [Probabilistic Graphical Models Specialization](#) vedený Daphne Koller, ktorý sme už vyššie spomínali v súvislosti s bayesovskými sieťami, sa okrem nich venuje aj markovovským a skrytým markovovským modelom.

Z nástrojov implementujúcich markovovské a skryté markovovské modely môžeme spomenúť napr. nasledujúce balíčky pre jazyk Python:

- **Scikit-learn; Python**, BSD licencia. Obsahuje, okrem mnohých ďalších metód, aj implementáciu skrytých markovovských modelov, vrátane učenia sa z dát a viacerých dekodovacích algoritmov.
- **Hmmlearn; Python**, BSD licencia. Implementuje skryté markovovské modely – inferenciu a nekontrolované učenie. Kontrolované učenie nepodporuje.

6.7 Rozhodovacie stromy a učenie na báze komisií

Ku oblasti rozhodovacích stromov a učení na báze komisií (či už založeného na rozhodovacích stromoch alebo na iných modeloch) existuje množstvo literatúry, keďže ide o veľmi populárne metódy. Spomeňme napr.:

- RUSSELL, S. – NORVIG, P. *Artificial Intelligence: A Modern Approach*. Prentice-Hall, 2010, third edition ed. ISBN 978-0-13-604259-4.

Jedna z najväčších klasík pre oblasť umelej inteligencie a strojového učenia – učebnica Russela a Norviga „Artificial Intelligence: A Modern Approach“ poskytuje veľmi široký prehľad o rôznych oblastiach a metódach umelej inteligencie. Ako inak, venuje sa aj rozhodovacím stromom.

- ROKACH, L. – MAIMON, O. Z. *Data Mining with Decision Trees: Theory and Applications*, vol. 81 of *Series in Machine Perception and Artificial Intelligence*. World Scientific, 2015, 2nd edition.

Táto publikácia poskytuje užitočný prehľad zameraný vyslovene na rozhodovacie stromy a metódy s nimi priamo súvisiace. Má jednak dosť široký záber (venuje sa aj metódam učenia pomocou komisií, fuzzy rozhodovacím stromom, vyhodnocovaniu úspešnosti učenia, aplikáciám rozhodovacích stromov v odporúčacích systémoch a pod.), ale ide aj do hĺbky a väčšinu metód vysvetľuje pomerne podrobne.

- SPALEK, J. – JANOTA, A. – BALAŽOVIČOVÁ, M. – PŘIBYL, P. *Decision Making and Control with Support of Artificial Intelligence (In Slovak: Rozhodovanie a riadenie s podporou umelej inteligencie)*. Žilinská univerzita v Žiline/EDIS, 2005. ISBN 80-8070-354-X.

Z publikácií v slovenskom jazyku môžeme spomenúť túto učebnicu, ktorá sa zaoberá viacerými oblasťami umelej inteligencie – okrem iného aj rozhodovacími stromami.

Keďže rozhodovacie stromy patria v oblasti dátovej analýzy medzi štandardne používané metódy a zároveň predstavujú jednu z dôležitých tém v oblasti strojového učenia, venuje sa im (aspoň okrajovo) aj pomerne veľký počet online kurzov. Môžeme z nich spomenúť napríklad nasledujúce:

- Kurz [Machine Learning for Data Analysis](#) z portálu [coursera.org](#).
- Kurz [Practical Machine Learning on H2O](#) z portálu [coursera.org](#).
- Kurz [Process Mining: Data science in Action](#) z toho istého portálu.
- Kurz [Intro to Machine Learning](#) z portálu [udacity.com](#).
- Kurz [Applied Machine Learning in Python](#) z portálu [coursera.org](#).

Zo zaujímavých online návodov a príkladov môžeme uviesť povedzme:

- Návod „[Building Decision Tree Algorithm in Python with scikit learn](#)“ na prácu s rozhodovacími stromami pomocou balíčka Scikit-Learn pre jazyk Python.
- Návod „[Decision Trees](#)“ na realizáciu klasifikácia a regresie pomocou rozhodovacích stromov z oficiálnej dokumentácie balíčka Scikit-Learn.
- Návody „[Decision Tree](#)“, „[Decision Tree in RapidMiner](#)“, „[Decision Tree based Classification Using RapidMiner](#)“ na realizáciu klasifikácie pomocou rozhodovacích stromov v nástroji RapidMiner.

Existuje pomerne veľa softvérových nástrojov, ktoré podporujú rozhodovacie stromy. Samozrejmosťou je ich podpora v rôznych softvérových nástrojoch určených na analýzu dát. Existujú tiež voľne dostupné implementácie pre rôzne programovacie jazyky. Zo všetkých existujúcich softvérových nástrojov môžeme spomenúť aspoň:

- **Scikit-learn; Python**, BSD licencia. Obsahuje – popri mnohých iných nástrojoch – implementáciu rozhodovacích stromov pre klasifikáciu a regresiu na báze metódy CART a metódy učenia pomocou komisií ako sú AdaBoost, náhodné lesy a gradientný boosting.
- Balíček **rpart** pre jazyk R, GPL-2/GPL-3.
- **XGBoost** C++, rozhrania pre Python, R, Java, Scala, C a ďalšie. Vie využiť platformy Hadoop, Spark, Flink a DataFlow určené na prácu s veľkými dátami.
- **RapidMiner**; komerčná licencia + open-source verzia s GPL licenciou. Grafický nástroj obsahujúci implementáciu rozhodovacích stromov pre klasifikáciu, náhodných lesov, gradientného boostingu a mnohých ďalších metód.

6.8 Metódy učenia s odmenou

Ku metódam učenia s odmenou existuje niekoľko dobrých publikácií. Tempo vývoja je však v súčasnosti dosť rapídne, metódy sa rýchlo vyvíjajú a dejú sa dosť podstatné zmeny. Preto sa učebnice rýchlo stávajú neaktuálnymi. Napriek tomu uvedieme niekoľko dobrých zdrojov, ktoré vysvetľujú základy:

- SUTTON, R. – BARTO, A. *Reinforcement Learning: An Introduction*. Adaptive Computation and Machine Learning. The MIT Press, 1998. ISBN 0262193981.

Bezpochyby najznámejšia klasika z oblasti učenia s odmenou. Učebnica poskytuje postupný úvod – začína od základov a intuícií, postupne zavádza základné definície a vysvetľuje jednotlivé algoritmy. Nevýhodou je, že ide o veľmi starú učebnicu.

- SUTTON, R. S. – BARTO, A. G. *Reinforcement Learning: An Introduction*. [online]. URL: <<http://incompleteideas.net/book/the-book-2nd.html>> (cit. 2018-01-26). Ed. 2, complete draft.

Vyššie spomenutá učebnica, ktorej autormi sú Sutton a Barto sa naprie svojmu veku stále teší veľkej obľube. Zrejme aj preto sa pripravuje ďalšie, aktualizované vydanie. V súčasnosti je už takmer dokončené a autori priebežne zverejňujú rozpracované verzie v elektronickej podobe.

- WIERING, M. – VAN OTTERLO, M. *Reinforcement Learning*. In *Adaptation, Learning, and Optimization*, zv. 12. Springer, 2012.

Publikácia viacerých autorov, ktorá sa snaží poskytnúť prehľad stavu poznania v oblasti učenia s odmenou. Predstavuje širokú paletu tém. Nevýhodou je, že vyšla v roku 2012, t.j. ešte predtým, ako sa začalo v rámci učenia s odmenou efektívne využívať

hlboké učenie. Z tohto dôvodu sú mnohé kapitoly publikácie v súčasnosti už menej aktuálne.

O hlbokom učení existujú dobré online kurzy, zahŕňajúce aj nové poznatky týkajúce sa hlbokého učenia s odmenou, napr.:

- Kurz Davida Silvera [Reinforcement Learning](#), prednášky z ktorého sú k dispozícii na [YouTube](#). Hoci sú prednášky z roku 2015, stále ešte predstavujú dobrý a pomerne aktuálny úvod do aktuálneho stavu poznania v oblasti učenia s odmenou. Medzitým síce vznikli viaceré ďalšie metódy a dosiahol sa značný pokrok, základy však poskytuje kurz veľmi solídne.
- K dispozícii sú tiež videá z prednášok v rámci predmetu [Deep Reinforcement Learning](#) poskytovaného Kalifornskou univerzitou v Berkeley – momentálne sú najaktuálnejšie videá z roku 2017, budú sa však zverejňovať aj videá z nasledujúcich rokov. Poznamenajme, že v tomto prípade nejde o online kurz v pravom slova zmysle – len o zverejnenie elektronických študijných materiálov.
- Kurz [Deep Reinforcement Learning](#) z portálu [Udacity](#) – v tomto prípade ide o plnohodnotný online kurz, po ktorého absolvovaní je možné získať aj certifikát.

Keďže v oblasti strojového učenia, vrátane hlbokého učenia s odmenou, v poslednom čase vzniká kultúra určitej otvorenosti, kde sa zdieľanie zdrojových kódov ku článkom považuje takmer za samozrejmosť, existuje mnoho implementácií týkajúcich sa metód učenia s odmenou. Ak by sme sa však mali zamerať len na projekty, ktoré sú cielene vyvíjané ako nástroje na učenie s odmenou a implementujú širšiu ponuku metód, stále je z čoho vyberať, napr.:

- [Keras-RL](#); **Python**, MIT licencia.

Balíček obsahuje implementácie viacerých metód hlbokého učenia s odmenou založené na nástroji [Keras](#). Implementuje napr. metódy DQN, DDQN, DDPG, CDQN, CEM a ďalšie.

- [Baselines](#); **Python**, MIT licencia.

Knižnica vyvinutá neziskovou firmou OpenAI. Založená je na frameworku TensorFlow a implementuje napr. metódy A2C, ACER, ACKTR, DDPG, DQN, GAIL, HER, PPO, TRPO.

- [RLlib](#); **Python**, Apache License 2.0.

Knižnica poskytovaná v rámci frameworku [Ray](#) od Kalifornskej univerzity v Berkeley. Framework Ray slúži vo všeobecnosti na distribuované riešenie výpočtovo náročných úloh. Obsahuje viacero knižníc – napr. na ladenie hyperparametrov a na

učenie s odmenou. Samotná knižnica RLLib implementuje viacero algoritmov na učenie s odmenou, napr. metódy Ape-X, DQN, DDPG, A3C, evolučné stratégie a ďalšie. Na hlboké učenie využíva buď framework Tensorflow alebo framework PyTorch.

6.9 Znalostné inžinierstvo a expertné systémy

- SPALEK, J. – JANOTA, A. – BALAŽOVIČOVÁ, M. – PŘIBYL, P. *Rozhodovanie a riadenie s podporou umelej inteligencie*. Žilinská univerzita v Žiline/EDIS, 2005. ISBN 80-8070-354-X.

Učebnica obsahuje viacero kapitol týkajúcich sa znalostného inžinierstva a expertných systémov. Výhodou je jazyková dostupnosť.

- NÁVRAT, P. – BIELIKOVÁ, M. – ĽUBICA BEŇUŠKOVÁ a kol. *Umelá inteligencia*. Vydavateľstvo STU, 2002. ISBN 80-227-1645-6.

Známa publikácia na tému umelej inteligencie v slovenčine. Pozostáva z troch dielov, pričom druhý z nich sa venuje znalostnému inžinierstvu.

- GIARRATANO, J. C. – RILEY, G. D. *Expert Systems: Principles and Programming*. 4th edition. ISBN 978-0534384470.

Jedna z klasík v oblasti expertných systémov. V prvej polovici sa venuje teórii a v druhej poskytuje ilustračné príklady založené na nástroji CLIPS.

- STAAB, S. – STUDER, R. *Handbook on Ontologies*. Springer Science & Business Media, 2009, second edition. ISBN 978-3540709992.

Publikácia venujúca sa ontológiám ako jednej z tém v rámci znalostného inžinierstva, reprezentácie poznatkov a logického odvodzovania z nich.

6.10 Multiagentové systémy

O oblasti multiagentových systémov sa možno viac dozvedieť napríklad z nasledujúcich zdrojov:

- WOOLDRIDGE, M. *An Introduction to Multiagent Systems*. John Wiley & Sons, 2009, second edition. ISBN 978-0470519462.

Zrejme jedna z najznámejších publikácií z oblasti multiagentových systémov. Autor sa zaoberá definíciami agentov, ich rôznymi druhmi, vysvetľuje, ako sa pri interakcii medzi agentmi uplatňujú koncepty z teórie hier, ako agenti môžu medzi sebou komunikovať a podobne.

- SHOHAM, Y. – LEYTON-BROWN, K. *Multiagent Systems: Algorithmic, Game-Theoretic, and Logical Foundations*. Cambridge University Press, 2008. ISBN 978-0521899437.

Táto publikácia začína všeobecným výkladom týkajúcim sa distribuovaného spĺňania ohraničení a distribuovanej optimalizácie. Následne pokračuje výkladom súvisiacich konceptov z kontextu teórie hier. V neskorších kapitolách sa však venuje aj otázkam učenia v hrách (napr. na báze učenia s odmenou) a klasickým konceptom z oblasti multiagentových systémov ako sú komunikácia medzi agentmi, protokolmi pre strategických agentov – založených na hlasovaní, aukciách a pod.

Čo sa týka nástrojov na implementáciu či simuláciu multiagentových systémov, je k dispozícii viacero možností, napr.:

- **MASON**; **Java**, Academic Free License (AFL) v. 3.0.

Nástroj na diskretnú udalostnú simuláciu multiagentových systémov. Obsahuje jednak samotné simulačné jadro a jednak nástroje slúžiace na vizualizáciu.

- **NetLogo**; **Java**, GPL.

NetLogo [5] je grafický nástroj určený na vývoj a simuláciu multiagentových systémov. Logika simulácie a správanie sa jednotlivých agentov sa definujú pomocou doménového jazyka vychádzajúceho z jazyka LOGO. Netlogo má integrovanú vizualizáciu a umožňuje ľahko tvoriť grafické rozhrania a pridávať do nich ovládacie prvky. Obsahuje aj množstvo pribalených modelov, ktorými sa možno inšpirovať pri zostavovaní nových simulácií.

Nevýhodou nástroja NetLogo – okrem toho, že si vyžaduje znalosť nového jazyka – sú dosť veľké výpočtové nároky. Porovnania ukazujú, že modely zostrojené v nástroji NetLogo sú napríklad podstatne pomalšie než modely vytvorené pomocou nástroja MASON.

6.11 Celulárne automaty

Z literatúry o celulárnych automatoch môžeme spomenúť napr. zdroje:

- SCHIFF, J. L. *Cellular Automata: A Discrete View of the World*, vol. 45. John Wiley & Sons, 2008. ISBN 978-0-0470-16879-0.

Publikácia poskytuje úvod do oblasti celulárnych automatov. Zaoberá sa 1- a 2-rozmernými celulárnymi automatmi. Podstatná časť publikácie sa venuje aplikáciám. Zahŕňa napr. aj tému evolúcie celulárnych automatov pomocou genetických algoritmov. Nevýhodou publikácie môže byť jej vek – nie všetky v nej obsiahnuté informácie musia byť nutne aktuálne.

- HADELER, K.-P. – MÜLLER, J., ed. *Cellular automata: analysis and applications*. Springer, 2017. ISBN 978-3319530420.

Z aktuálnejších publikácií môžeme spomenúť napríklad tento zborník prác viacerých autorov, zaoberajúci sa jednak úvodom do problematiky celulárnych automatov, ich históriou a teoretickými vlastnosťami, a jednak ich rôznymi aplikáciami.

Existuje viacero online kurzov, ktoré sa – väčšinou popri iných témach z oblasti simulácie a modelovania – venujú aj celulárnym automatom. Môžeme z nich spomenúť napríklad:

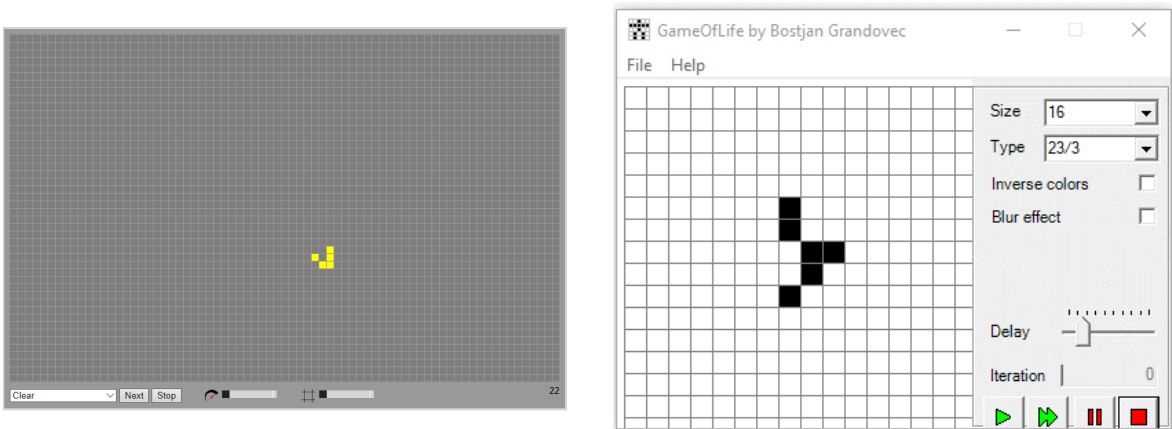
- Kurz [Simulation and Modeling of Natural Processes](#) z portálu [coursera.org](#).
- Kurz [Model Thinking](#) z portálu [coursera.org](#).
- Kurz [Decision Making in a Complex and Uncertain World](#) z portálu [futurelearn.com](#).

Zo zaujímavých online návodov a príkladov môžeme uviesť napríklad niekoľko návodov na implementáciu hry života v jazyku Python:

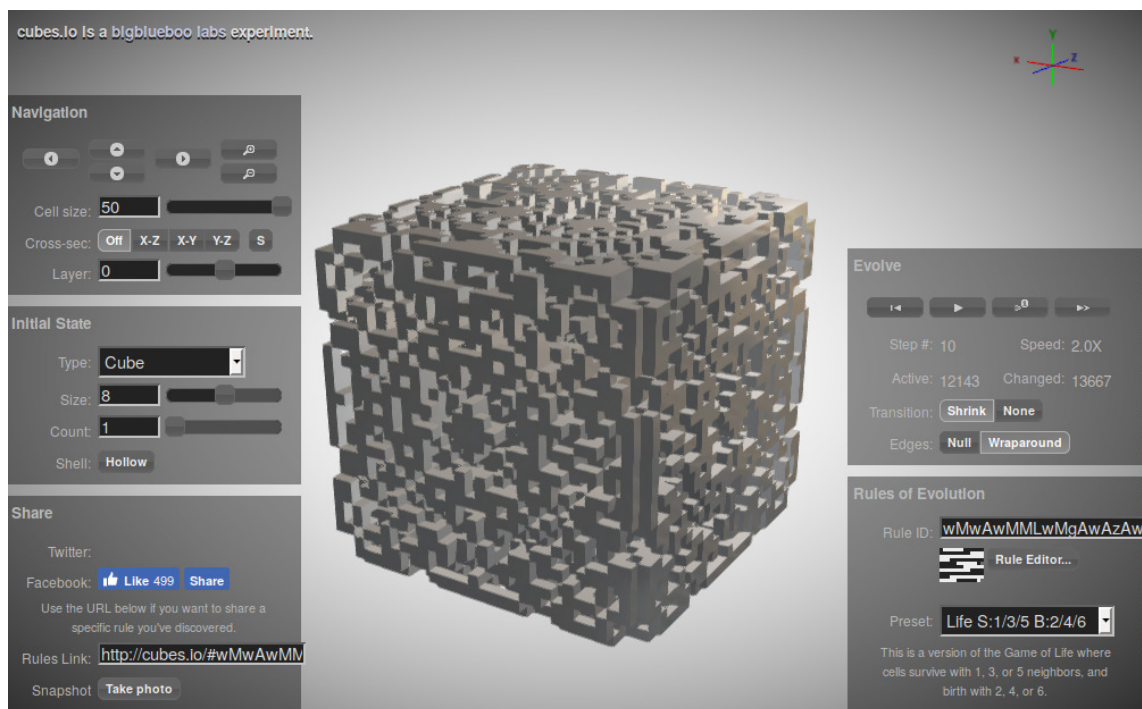
- Jednoduchý video návod „[Cellular Automata: Part 1 - Setting up our Pyglet Window](#)“ (odkaz je na prvú časť; dokopy sú štyri časti) ku vytvoreniu simulácie hry života v jazyku Python je možné nájsť na YouTube.
- Návod na implementáciu hry života pre Python „[Conway’s Game of Life in python](#)“, vizualizujúci výstupy prostredníctvom knižnice `matplotlib` s možnosťou generovania animovaných gifov.
- Návod „[Conway’s Game of Life in Python](#)“ na implementáciu hry života v jazyku Python s interaktívnymi javascriptovými vizualizáciami.

K dispozícii je aj viacero zaujímavých interaktívnych demonštrácií:

- Príklady aplikácií umožňujúcich simulovať hru života:
 - Webová aplikácia „[John Conway’s Game of Life](#)“.
 - Aplikácia [Game of Life](#) pre PC.
 - Mobilná aplikácia „[Conway Game of Life](#)“.
- Zaujímavú webovú aplikáciu založenú na WebGL poskytuje stránka [cubes.io](#). Umožňuje interaktívne simulovať evolúciu v 3-rozmerných bunkových automatoch. Umožňuje nastaviť počiatočný stav, pomocou vstavaného editora vytvoriť požadované pravidlá a spustiť evolúciu. Okrem celého 3-rozmerného telesa umožňuje táto aplikácia vizualizovať aj jeho jednotlivé rezy.



Obr. 11: Hra života pre ako webová aplikácia (vľavo) [6] a program pre PC (vpravo) [7].




Obr. 12: Aplikácia cubes.io.

- Blog o procedurálnom generovaní levelov v počítačových hrách „[The Cellular Automaton Method for Cave Generation](#)“ obsahuje aj interaktívnu simuláciu, ktorú možno nájsť na stránke <http://j2kun.github.io/cave-automata/index.html>. Ukážka možného procedurálne vygenerovaného levelu je na Obr. 13.

Existuje viacero softvérových nástrojov, v ktorých možno simulovať evolúciu celulárnych automatov a vizualizovať jej priebeh. Môžeme z nich spomenúť napríklad:

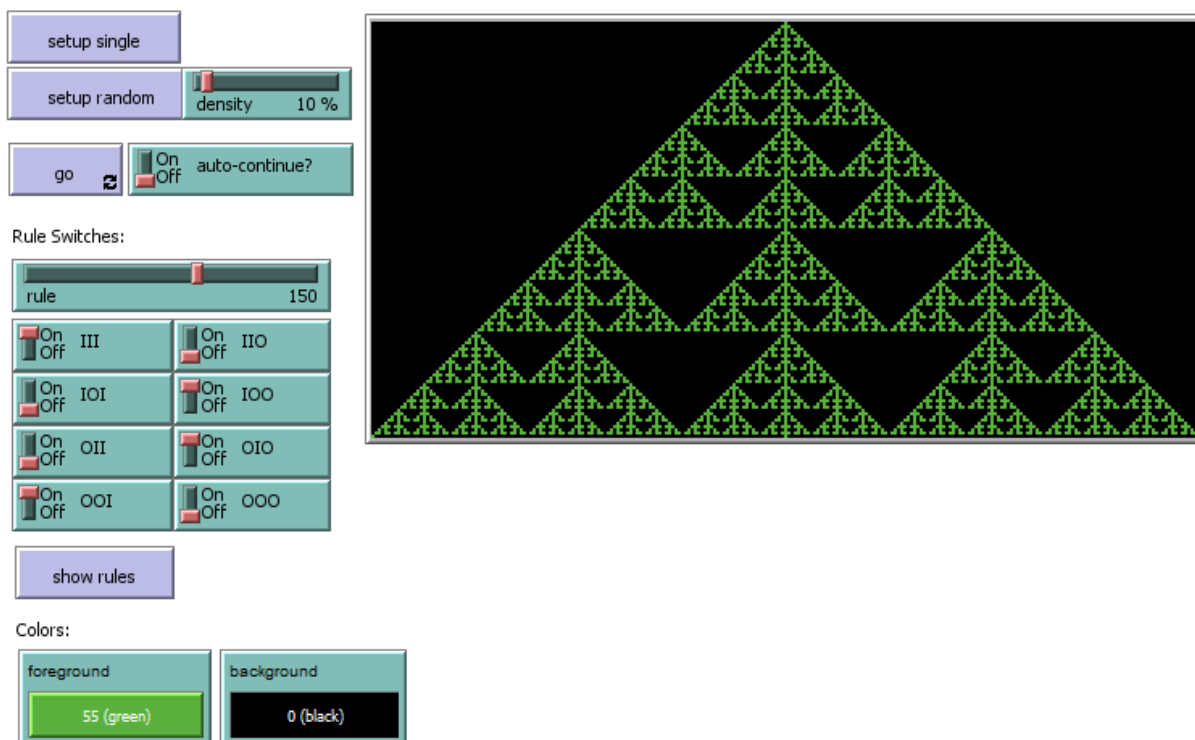
- **NetLogo**; Java, GPL.

NetLogo [5] je nástroj primárne určený na vývoj multiagentových systémov. Je v ňom, okrem mnohých iných systémov, možné simulovať aj celulárne automaty. Pre



Obr. 13: Ukážka možného procedurálne vygenerovaného levelu.

účely ilustrácie uvádzame jeden z CA modelov implicitne vstavaných do knižnice používateľských modelov „CA 1D Elementary“ (v kategórii Sample Models >Computer Science >Cellular Automata). V rámci neho bolo pre porovnanie nastavené to isté pravidlo 150 (Obr. 14), ktoré je diskutované v predošlých odstavcoch.



Obr. 14: Implementácia pravidla 150 v prostredí NetLogo ver. 6.0.4 [8].

Okrem počiatočného nastavenia a zobrazenia požadovaného typu pravidla (po bitoch

alebo pohybom posúvacej lišty na základe identifikačného čísla pravidla) umožňuje model rôznych typov iniciácií – od vyznačenia jednej bunky po náhodné počiatočné rozmiestnenie buniek na základe hustoty. Zdrojový kód modelu je k dispozícii takisto v [8].

- **JCASim**; **Java**, LGPLv2.

Javový nástroj na simuláciu celulárnych automatov. K dispozícii je jednak samostatná javová aplikácia a jednak webový applet. Na webovej stránke projektu je možné nájsť aj viacero modelových príkladov určených pre JCASim.

- **CellPyLib**; **Python**, Apache License 2.0.

Knihnica pre jazyk Python, umožňujúca simuláciu 1 a 2-rozmerných celulárnych automatov.

6.12 Zhhlukovanie

Z bohatej literatúry týkajúcej sa zhhlukovania vyberáme nasledujúcich niekoľko titulov:

- MAIMON, O. Z. – ROKACH, L. *Data Mining and Knowledge Discovery Handbook*. Springer, 2010, second edition. ISBN 978-0-387-09823-4.

Publikácia obsahuje dobrý prehľad metód zhhlukovania – počínajúc od hierarchického zhhlukovania a metódy k-means cez DBSCAN, fuzzy zhhlukovanie až po modelové metódy a metódy pre rozsiahlejšie dátové množiny.

- LESKOVEC, J. – RAJARAMAN, A. – ULLMAN, J. D. *Mining of Massive Datasets*. Stanford University. [online], 2014. URL: <<http://infolab.stanford.edu/~ullman/mmds/book.pdf>> (cit. 2016-10-24).

Publikácia venujúca sa problematike zhhlukovania v kontexte veľkých dát. Okrem základných, ilustratívnych metód zhhlukovania sa teda autori venujú aj metódam, ktoré majú lepšiu škálovateľnosť a je ich možné použiť v prípade väčších dátových množín.

Na tému zhhlukovania je k dispozícii viacero online kurzov. Zhhlukovanie je väčšinou prezentované buď ako jedna téma v rámci širšieho kurzu o strojovom učení alebo ako jeden menší kurz v rámci špecializácie:

- Na portáli **Coursera** je v rámci špecializácie **Machine Learning** od University of Washington k dispozícii kurz **Clustering and Retrieval** venovaný problematike zhhlukovania.
- Zhhlukovaniu sa venuje aj kurz **Machine Learning: Unsupervised Learning** z portálu **Udacity** zaoberajúci sa nekontrolovaným učením.

- Podobne možno informácie o zhlukovaní čerpať aj z kurzu [Machine Learning](#) na portáli [edx](#) alebo z mnohých iných online kurzov.

Nástrojov implementujúcich rozličné metódy zhlukovania je pomerne veľký počet. Budeme sa opäť sústrediť najmä na python-ové balíčky, spomenieme však aj niekoľko iných alternatív:

- **Scikit-learn; Python**, BSD licencia. Obsahuje implementáciu viacerých metód zhlukovania, napr. hierarchického zhlukovania, k-means, DBScan, spektrálne zhlukovanie, Bierch a iné.
- **Spark; Python, Java, Scala**, Apache License 2.0. Distribuovaný nástroj na prácu s veľkými dátovými množinami. Pribalená knižnica MLlib obsahuje implementáciu niekoľkých metód zhlukovania.
- **RapidMiner**; komerčná licencia + open-source verzia s GPL licenciou. Grafický nástroj obsahujúci implementáciu viacerých metód zhlukovania.

6.13 Vyhodnocovanie úspešnosti učenia

Pri hodnotení modelov a metód učenia je treba poznať metódy, ktorými sa vyhodnocuje úspešnosť učenia. Z literatúry týkajúcej sa tejto problematiky môžeme uviesť napríklad:

- FAWCETT, T. *An introduction to ROC analysis*. Pattern recognition letters, 27(8):861–874, 2006.

Úvodný text na tému ROC analýzy. Venuje sa aj téme ROC analýzy pri klasifikácii do viacerých tried – ale len okrajovo.

- SOKOLOVA, M. – LAPALME, G. *A systematic analysis of performance measures for classification tasks*. Information Processing & Management, 45(4):427–437, 2009.

Užitočný prehľad existujúcich chybových mier pre klasifikačné úlohy (uvažuje binárne problémy, problémy s viacerými triedami, klasifikáciu tej istej vzorky do viacerých tried, hierarchické úlohy, ...). Obsahuje aj prehľadové tabuľky so vzorcami na výpočet jednotlivých ukazovateľov.

- MONARD, M. C. – BATISTA, G. E. *Learning with Skewed Class Distributions*. Advances in Logic, Artificial Intelligence, and Robotics: LAPTEC 2002, 85:173, 2002.

Článok týkajúci sa učenia z dátových množín s nerovnomerne zastúpenými triedami. Ide už o starší článok, ale predsa predstavuje niektoré zaujímavé, hoci dnes už klasické, metódy ako je napr. metóda Tomekových väzieb.

- CHAWLA, N. V. *Data mining for imbalanced datasets: An overview*. In Data mining and knowledge discovery handbook, pp. 853–867. Springer, 2005.

Prehľadový článok o dolovaní v dátach s nerovnomerným zastúpením tried. Obsahuje časť o ROC analýze a prehľad niekoľkých stratégií vrátane rozdielneho váhovania tried v rámci chybovej funkcie a prevzorkovania (SMOTE, SMOTEBoost, ...)

- JAMES, G. – WITTEN, D. – HASTIE, T. – TIBSHIRANI, R. *An introduction to statistical learning*. Springer, 2013. ISBN 978-1-4614-7138-7.

Zaujímavá knižná publikácia s úvodom do metód učenia z pohľadu štatistiky. Obsahuje okrem iného aj časť o vyhodnocovaní úspešnosti učenia.

Vzhľadom na to, že problematika vyhodnocovania úspešnosti má v kontexte strojového učenia veľký význam, venuje sa jej aj viacero online kurzov a návodov. Z kurzov môžeme spomenúť kurz Andrewa Ng na portáli [Coursera](#) s názvom [Machine Learning](#). Prednáška na súvisiacu tému je súčasťou šiesteho týždňa kurzu.

Z praktických online návodov môžeme uviesť napríklad:

- [Návod o metrikách](#) na vyhodnocovanie úspešnosti strojového učenia pre Python.
- [Návod o validácii rozdelením a krížovej validácii](#) pre Python.

Metódy a nástroje na vyhodnocovanie úspešnosti učenia existujú prirodzene pre rôzne prostredia a programovacie jazyky – nie je ich možné všetky vymenovať. Budeme sa preto sústrediť primárne na jazyk Python, keďže sa v komunite strojového učenia teší v súčasnosti jednoducho najväčšej obľube:

- Balíček **scikit-learn**; Python, BSD licencia.

Obsahuje viacero [nástrojov](#), ktoré pomáhajú vyhodnotiť úspešnosť modelov, napríklad:

- krížová validácia, validácia rozdelením (`cross_validation`; k -násobná krížová validácia, `leave-one-out`, stratifikácia, ...);
- ROC analýza (`metrics.roc_curve`);
- matica zámien (`metrics.confusion_matrix`);
- ukazovatele MAE, MDAE, senzitivita, špecificita, správnosť, presnosť, koeficient determinácie a ďalšie (`metrics`);
- ...

- Balíček **imbalanced-learn**; Python, MIT licencia.

Obsahuje nástroje na prácu s dátovými množinami s nerovnomerným zastúpením tried, vrátane nástrojov na podvzorkovanie, nadvzorkovanie a pod.

- **Toolbox Statistics and Machine Learning Toolbox; Matlab**, komerčná licencia. Obsahuje pomocné funkcie na realizáciu krížovej validácie, leave-one-out validácie a pod.


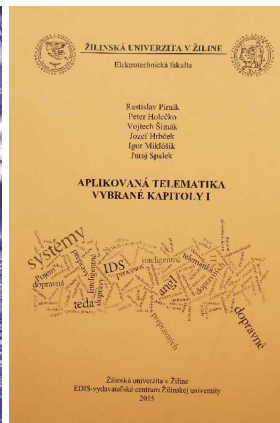




7 Učebnice katedry KRIS

Členovia katedry riadiacích a informačných systémov (KRIS), ktorá je nositeľom projektu KEGA 014ŽU-4/2018, vydali v minulosti viacero učebníc súvisiacich s umelou inteligenciou a strojovým učením, ktoré môžu poslúžiť ako hodnotné zdroje ku viacerým oblastiam UI a ML. Ide najmä o nasledujúce tituly:

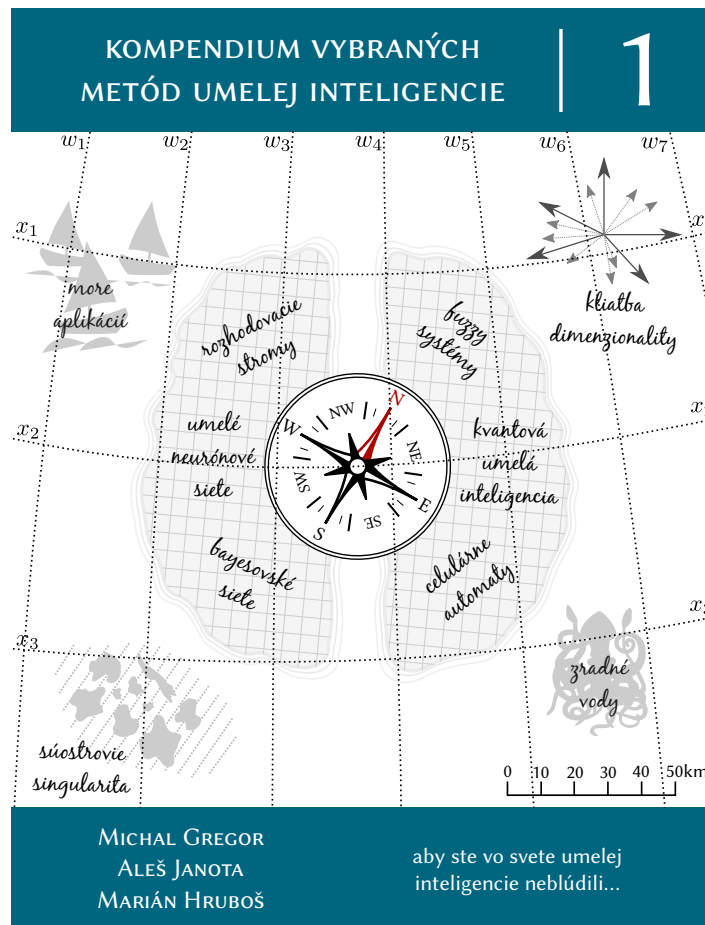
- GREGOR, M. *Umelá inteligencia 1*. Žilina: CEIT, a.s., 2014. ISBN 978-80-971684-1-4.
- GREGOR, M. – NEMEC, D. – HRUBOŠ, M. – SPALEK, J. *Umelá inteligencia 2: Hlboké učenie*. CEIT, a.s., 2017. ISBN 978-80-89865-03-1.
- GREGOR, M. – HRUBOŠ, M. – NEMEC, D. *Umelá inteligencia, skriptá I: Návod na vybrané cvičenia*. CEIT, a.s., 2017. ISBN 978-80-89865-02-4.
- SPALEK, J. – JANOTA, A. – BALAŽOVIČOVÁ, M. – PŘIBYL, P. *Rozhodovanie a riadenie s podporou umelej inteligencie*. Žilinská univerzita v Žiline/EDIS, 2005. ISBN 80-8070-354-X.
- JANOTA, A. – FRANEKOVÁ, M. – HOLEČKO, P. et al. *Aplikovaná telematika*. EDIS – vydavateľské centrum Žilinskej univerzity, 2015. ISBN 978-80-554-1037-1.
- PIRNÍK, R. – HOLEČKO, P. – ŠIMÁK, V. et al. *Aplikovaná telematika: Vybrané kapitoly I*. 2015. ISBN 9788055409764.
- JANOTA, A. – VESTENICKÝ, P. – PIRNÍK, R. et al. *Aplikovaná telematika: Vybrané kapitoly II*. 2015. ISBN 978805541043.

7.1 Kompendium

Okrem vyššie uvedených učebných textov sa v rámci riešenia projektu KEGA 014ŽU-4/2018 pripravuje aj nová publikácia s názvom „Kompendium vybraných metód umelej inteligencie“, ktorá by mala vyjsť na konci roka 2018. Jej cieľom je poskytnúť vysokoúrovňový, čitateľsky dostupnejší pohľad na vybrané témy z oblasti umelej inteligencie a strojového učenia. Tento prvý diel kompendia sa má venovať konkrétne nasledujúcim témam:



Obr. 15: Obálky učebníc a skript katedry KRIS.



Obr. 16: Obálka pripravovaného kompendia.

- fuzzy prístupy,
- bayesovské siete,
- umelé neurónové siete a hlboké učenie,
- rozhodovacie stromy,
- celulárne automaty,
- úvod do kvantovej umelej inteligencie.

8 Záver

Ako to dokumentuje materiál obsiahnutý v tejto správe, v oblasti umelej inteligencie a strojového učenia existuje veľké, takmer nepreberné množstvo úloh a metód, ako aj zdrojov, z ktorých možno čerpať informácie o nich.

Cieľom správy bolo poskytnúť vysokoúrovňový prehľad aspoň o tých najvýznamnejších odvetviach a ku každému z nich vymenovať niekoľko užitočných zdrojov, materiálov či nástrojov.

Členovia katedry riadiacich a informačných systémov (KRIS) vydali už v minulosti viacero vysokoškolských učebníc a iných učebných textov, venujúcich sa oblasti umelej inteligencie a strojového učenia. Tento dokument má poslúžiť aj ako podklad ku príprave ďalšieho študijného materiálu tohto typu.

Práca na príprave tohto nového knižného titulu s názvom „Kompendium vybraných metód umelej inteligencie“ už tiež začala a jeho vydanie sa predpokladá na konci roka 2018.

Literatúra

- [1] RUSSELL, S. – NORVIG, P. *Artificial Intelligence: A Modern Approach*. Prentice-Hall, 2010, third edition. ISBN 978-0-13-604259-4.
- [2] SINGH, S. – BARTO, A. – CHENANTEZ, N. *Intrinsically Motivated Reinforcement Learning*. In 18th Annual Conference on Neural Information Processing Systems (NIPS). 2004.
- [3] CHAPELLE, O. – SCHÖLKOPF, B. – ZIEN, A. *Semi-Supervised Learning*. Cambridge, Massachusetts: The MIT Press, 2006. ISBN 978-0-262-03358-9.
- [4] KRÖSE, B. – SMAGT, P. v. D. *An Introduction to Neural Networks*. Amsterdam, The Netherlands: University of Amsterdam, 1996.
- [5] WILENSKY, U. *NetLogo*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. [online], 1999. URL: <<http://ccl.northwestern.edu/netlogo/>> (cit. 2018-07-13).
- [6] MARTIN, E. *John Conway's Game of Life*. [online]. URL: <<https://bitstorm.org/gameoflife/>> (cit. 2018-07-13).
- [7] GRANDOVEC, B. *Game of Life*. [online]. URL: <<http://freeweb.siol.net/bgrandov/Content/GameOfLife.htm>> (cit. 2018-07-03).
- [8] WILENSKY, U. *NetLogo CA 1D Elementary Model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. [online], 1998. URL: <<http://ccl.northwestern.edu/netlogo/models/CA1DElementary>> (cit. 2018-07-13).