

# Poznávanie, umelá inteligencia a strojové učenie

Jozef Svitek<sup>1</sup>

Umelá inteligencia zaznamenala v posledných rokoch významný rozmach. V niektorých smeroch, ako napríklad rozpoznávanie objektov, alebo rozpoznávanie hovorenej reči dosiahla a v určitých prípadoch prekonala úroveň, ktorú dosahuje človek. Má stále širšie využitie v rôznych oblastiach ľudskej činnosti. Špecifickou témou sú filozofické, etické bezpečnostné a ďalšie aspekty spojené so všeobecnou umelou inteligenciou (Artificial General Intelligence - AGI) a super inteligenciou vedúcou ku vzniku tzv. singularity, kedy by umelé systémy prekonali svojou inteligenciou ľudskú inteligenciu.

Strojové učenie (Machine Learning) je časťou problematiky súvisiacej s umelou inteligenciou. Zaoberá sa počítačovými systémami a algoritmami, ktoré dokážu riešiť špecifické úlohy pozostávajúce z komplexných procesov, na základe učenia sa z poskytnutých dát, bez vopred naprogramovaných pravidiel.

Vznik inteligentných systémov je spätý so schopnosťou učenia sa. Zrejme je vhodné pozrieť sa bližšie na tento proces v živých systémoch - od tých najjednoduchších až po človeka. Tak môžeme lepšie posúdiť paralely a odlišnosti strojového učenia a porovnať s tým, ako prebieha učenie v živých organizmoch a u človeka.

## Živé organizmy a poznávanie

Akýkoľvek živý systém sa vyznačuje tým, že zaznamenáva relevantné vlastnosti svojho prostredia a reaguje tak, aby dokázal v danom prostredí prežiť (Kováč, 2000). Mnohé rysy daného prostredia môžu predstavovať problém, ktorý je pre ďalšie pretrvanie organizmu potrebné vyriešiť. Riešením je zabudovaná znalosť, predpis ako konať v záujme zachovania svojej existencie - adaptácia.

V rôznorodom a meniacom sa prostredí sveta bolo a je potrebné prekonávať rozmanité nepriaznivé podmienky, čo vedie ku komplexnosti uložených znalostí. Vyššia komplexnosť predstavuje väčší potenciál pre prežitie v danom prostredí. Na všetkých úrovniach života je celková konštrukcia organizmu výsledkom uložených znalostí a predstavuje epistemickú komplexnosť. Život je tak poznávacím systémom a biologická evolúcia je kontinuálnym rastom poznania, vytváraním subjektov so stále širšími zabudovanými znalosťami.

Toto veľmi zjednodušene vyjadruje, že v prípade biologických systémov poznávanie znamená spôsoby reakcie na zmeny v okolitom prostredí, ktoré sa prejavujú zmenou v samotnom organizme - zabudovanou znalosťou, ktorá zvyšuje jeho šance na prežitie.

## Ľudská myseľ a poznávanie

Snahy o pochopenie ľudskej mysle siahajú hlboko do minulosti. Skúmaním mozgu ako systému spracovania informácií sa zaoberá kognitívna veda. Jej vývoj sprevádzali štyri významné paradigmy: symbolizmus, konekcionizmus, dynamické systémy a pravdepodobnostné systémy (Farkaš et al., 2013).

**Symbolizmus** – poníma myseľ ako výpočtový stroj, oddeliteľný od prostredia, ktorý manipuluje s internými symbolmi podľa logických pravidiel podobne ako to robí počítač. Základným konceptom výpočtovej teórie mysle je mentálna reprezentácia vonkajších vnemov, podľa ktorej sú kognitívne stavy a procesy konštituované výskytom, transformáciou a uchovávaním v mysli. Ide o abstraktné objekty so sémantickými vlastnosťami, ktoré predstavujú reprezentáciu znalostí takým spôsobom, aby sa dali používať v symbolovom systéme. Z pohľadu symbolizmu je myslenie človeka riadené algoritmami implementovanými v mysli s využitím vhodných reprezentácií. Spôsob implementácie algoritmov symbolizmus nerieši.

---

<sup>1</sup> Ing. Jozef Svitek, PhD., IT konzultant, +421 903 414 108, [jozefsvitek1@gmail.com](mailto:jozefsvitek1@gmail.com),

**Konekcionizmus** – vychádza z predstavy siete vytvorenej z neurónov, základných stavebných prvkov nervového systému. Konekcionistický systém, inšpirovaný touto predstavou, pozostáva z množiny jednoduchých prvkov - umelých neurónov, ktoré navzájom komunikujú cez váhové prepojenia, predstavujúce dlhodobú pamäť systému. Výpočtová schopnosť umelej neurónovej siete nie je v samotných neurónoch, ale v ich vzájomnom prepojení a interakcii. Komunikácia medzi neurónmi má numerický, nie symbolový charakter. Dôležitou vlastnosťou umelých neurónových sietí je, že parametre siete (váhy prepojení neurónov) nemusíme (ani nedokážeme) explicitne nastaviť, ale využíva proces učenia prostredníctvom tréningových dát, ktoré je potrebné sieti poskytnúť. Učenie spočíva v zmenách váh prepojení tak, aby bol nájdený extrém nejakej hodnotovej funkcie. Neurónové siete tak poskytujú biologicky inšpirované procesy učenia sa.

**Dynamické systémy** – predpokladajú priebežnú interakciu s prostredím (na rozdiel napr. od neurónových sietí, kde tréningové dáta sú v dávkach v procese učenia a výstupy siete nemajú vplyv na prostredie). Súčasťou dynamického opisu kognitívneho procesu sa stáva aj prostredie. To vedie k teórii nelineárnych dynamických systémov. Predpokladá existenciu dvoch typov premenných. *Kolektívne premenné*, ktoré reprezentujú vzťahy medzi interagujúcimi časťami systému a *riadiace parametre*, ktoré môžu vyvolať zmeny v správaní systému.

**Pravdepodobnostný model** – spočíva vo vyhodnocovaní zhody pravdepodobnostných (v špeciálnych prípadoch aj logických) teórií s existujúcimi dátami. Podľa niektorých štúdií (Bonawitz et al., 2014) pravdepodobnostný prístup vysvetľuje viaceré prejavy ľudského správania.

Uvedené paradigmy umožňujú lepšie chápať viaceré skutočnosti spojené s poznávaním a pomáhajú implementovať podobné princípy v umelej inteligencii. Napriek biologickej inšpirácii a mnohým úspešným aplikáciám, nevysvetľujú kľúčové aspekty ľudského poznávania. Napríklad riešenie náročných výpočtových problémov, rozpoznávanie scény, porozumenie rôznym nuansám pri vnímaní jazyka.

## Umelá inteligencia

Existuje viacero rôznych definícií umelej inteligencie (Russel, Norvig, 2010), ale zvyčajne sa stretávame s voľnou definíciou, že je to inteligencia preukazovaná strojmi. Zahŕňa veľmi širokú oblasť, ktorá sa postupne rozdelila na viacero samostatných disciplín:

- dedukcia, uvažovanie, vyvodzovanie záverov
- rozpoznávanie obrazu a objektov
- rozpoznávanie reči, automatické preklady so zohľadnením kontextu
- riadenie robotov
- vyhľadávanie
- hranie hier
- reprezentácia zozbieraných dát
- iné.

Medzi populárne úspechy umelej inteligencie sa uvádza šachové víťazstvo počítača IBM Deep Blue nad majstrom sveta v šachu Garry Kasparovom v roku 1997. Z pohľadu AI bolo víťazstvo dôsledkom kombinácie priemerných šachových znalostí a obrovskej rýchlosti pri vyhľadávaní možných kombinácií. Ďalším triumfom bolo prekvapujúce víťazstvo AlphaGo od Googlu nad svetovým šampiónom Lee Sedolom v hre Go v roku 2016. V tomto prípade bola využitá technológia umelých neurónových sietí (Deep Learning - DL) on Deep Neural Network - DNN) v kombinácii s masívnym paralelným stromovým vyhľadávaním a reinforcement learning<sup>2</sup> – podrobnejšie sa o uvedených pojmoch zmienime neskôr.

---

<sup>2</sup> Pokiaľ nie sú ustálené slovenské názvy, budeme využívať anglickú terminológiu.

## Vznik a vývoj umelej inteligencie

Za počiatok rozvoja umelej inteligencie možno považovať návrh modelu umelého neurónu (Warren McCulloch a Walter Pitts (1943) (Russel, Norvig, 2010). V roku 1950 zostrojili Marvin Minsky a Dean Edmonds prvú počítačovú neurónovú sieť SNARC. K rozvoju novej vednej disciplíny medzi inými významne prispeli Donald Hebb, John von Neumann a Alan Turing, ktorý vo svojej práci z roku 1950 „Computing Machinery and Intelligence“ uviedol známy Turingov Test.

V roku 1956 zorganizoval John McCarthy v Dartmouth College dvojmesačný workshop, kde bol prvý krát použitý termín „Artificial Intelligence (AI)“ – umelá inteligencia. Aj keď workshop nevedol k žiadnemu prelomovému posunu, je považovaný za zrod samostatného vedného odboru. Rozvoj umelej inteligencie v ďalších rokoch bol vo veľkej miere determinovaný úrovňou procesorov a existujúcej výpočtovej kapacity. Začiatok komerčného využívania poznatkov spojených s AI spadá do osemdesiatich rokov, kedy začala éra expertných systémov. Kontinuálne zlepšovanie technických parametrov procesorov a ďalších hardvérových komponentov, internet a s ním spojený celosvetový nárast generovaných dát boli impulzom pre novú vlnu záujmu o AI v posledných rokoch. V súčasnosti existuje mnoho rôznych praktických aplikácií umelej inteligencie, ktoré bežne využívame. Napríklad pri zadávaní hlasových príkazov, vyhľadávani na internete, navigácii, asistovanom riadení áut, pri videohrách a v mnohých ďalších oblastiach.

## Umelé neurónové siete – Deep Neural Network (DNN), Deep Learning (DL)

Základné princípy umelých neurónových sietí sú známe už desiatky rokov, neboli však veľmi využívané v praktických aplikáciách. Zmena nastala niekedy okolo roku 2010 a bola výsledkom postupného vývoja v dvoch zdanlivo nesúvisiacich oblastiach: 1) rýchly grafický procesor (GPU), ktorého maticová štruktúra sa výborne hodila do architektúry neurónových sietí, 2) veľké označené datasety (digitálne obrázky, sociálne siete a pod.), ktoré mohli byť použité na tréning DNN. Grafický procesor umožňoval vytvorenie oveľa väčších sietí z vyšším počtom vrstiev („Deep Neural Network“) a táto kombinácia dala vzniknúť novej paradigme „Deep Learning“. Pri použití DNN klesla chybovosť pri rozpoznávaní obrazcov z 25% v roku 2011 na 3% v roku 2015, čo je lepšie ako v prípade ľudí, kde je to okolo 5%. Microsoft oznámil, že jeho neurónová sieť dosahuje pri prepise hovoreného slova do textovej podoby chybovosť 5,1%, čo zodpovedá ľudským zapisovateľom, ktorí si však môžu text vypočítať viackrát (PC Revue 10/2017 s.8).

Umelé neurónové siete sú inšpirované fungovaním nervového systému, ktorého základnými stavebnými prvkami sú nervové bunky – neuróny. Vzájomným prepojením jednotlivých neurónov vznikne neurónová sieť. Prepojenie je realizované tak, že výstupné impulzy neurónu sú privedené na vstupy ďalších neurónov. Základná topológia siete pozostáva zo vstupnej vrstvy, jednej alebo viacerých skrytých vrstiev a výstupnej vrstvy. Na učenie siete sa používa napríklad algoritmus spätného šírenia. Je založený na porovnaní skutočného výstupu siete s očakávanou hodnotou a následnej adaptácii váh a prahov jednotlivých neurónov smerom od výstupnej vrstvy ku vstupnej. Každý cyklus učenia pozostáva teda z dvoch prechodov:

- **Prechod dopredu** – signál je aplikovaný na vstupnú vrstvu a postupne sa šíri jednotlivými vrstvami až po výstupnú vrstvu. Tam sa porovná výstupný signál s očakávanými hodnotami výstupného vektora.
- **Prechod späť** – na základe rozdielu medzi výstupným signálom a očakávanými hodnotami získame chybovú funkciu, ktorá sa šíri od poslednej vrstvy v spätnom smere a postupne sa upravujú váhy neurónov vo všetkých vrstvách proti gradientu chybovej funkcie.

Pri ďalšom prechode prechádza signál dopredu neurónmi s upravenými váhami a celý cyklus sa mnohokrát opakuje, až kým nedosiahne chybová funkcia požadovanú hodnotu, alebo sa nenaplní počet plánovaných iterácií.

Celková sada vstupno-výstupných údajov je obvykle náhodne rozdelená na tri časti: tréningovú, validačnú a testovaciu. Validačné dáta slúžia na doladenie parametrov používaných pri tréningu,

napríklad koeficient učenia, sieťovú architektúru a podobne. Testovacie dáta umožňujú posúdiť výsledné fungovanie DNN.

## Strojové učenie (Machine Learning - ML)

Strojové učenie je súčasť umelej inteligencie. Len ťažko si možno predstaviť vytvorenie inteligentného systému schopného vykonávať akékoľvek aktivity, ktoré zvykneme spájať s inteligenciou, bez schopnosti učenia.

### Agent

Pri skúmaní ďalších možností strojového učenia je vhodné zaviesť pojem agenta, ktorý je v umelej inteligencii široko vyžívaný. Bez nároku na úplnosť môžeme agenta opísať nasledovne:

Počítačový agent predstavuje entitu, ktorá funguje autonómne, prostredníctvom senzorov vníma svoje prostredie, reaguje na zmeny, vytvára ciele a vykonáva aktivity smerujúce k ich dosiahnutiu. Inteligentní agenti sa môžu učiť a využívať znalosti na dosiahnutie najlepších výsledkov, alebo, v prípade neurčitosti, najlepších možných výsledkov. Inteligentní agenti sú abstraktné funkčné systémy riadené počítačovým programom, preto sa niekedy nazývajú abstraktní inteligentní agenti (Russel, Norvig, 2010).

### Mechanizmy spojené so strojovým učením

Umelá neurónová sieť predstavuje jeden možný mechanizmus učenia prostredníctvom dát – teda za pomoci príkladov vstupov a im zodpovedajúcich výstupov je vytvorená všeobecná funkcia, alebo pravidlo podľa ktorých sú spracovávané ďalšie vstupy. Je to príklad **induktívneho učenia**. Poznáme tiež analytické, alebo **deduktívne** učenie, keď sa zo známych všeobecných princípov vytvorí nové pravidlá, ktoré umožňujú efektívnejšie postupy. Ďalšou možnosťou je **štatistický prístup**, kde učenie spočíva v odvodzovaní pravdepodobnostných záverov.

Existujú tri typy spätnej väzby, ktoré určujú tri hlavné spôsoby učenia. Môžeme ich označiť ako algoritmy s nekontrolovaným učením, niekedy nazývané učením bez učiteľa, (anglicky „unsupervised learning“), algoritmy s kontrolovaným učením, alebo učením s učiteľom („supervised learning“) a algoritmy učenia posilňovaním, alebo učenie odmenou a trestom („reinforcement learning“). V ďalšom texte budeme používať ustálené a všeobecne používané anglické názvy.

**Unsupervised learning** – v tomto prípade hľadá agent vo vstupných dátach určité vzory, alebo charakteristiky bez toho, aby dostal pokyny čo presne má hľadať. Najčastejším prípadom je hľadanie rôznych zhlukov (clustering), ktoré môžu predstavovať potenciálne zaujímavé usporiadanie vstupných dát.

**Reinforcement learning** – pri tomto type učenia dostáva agent v každom kroku „odmenu“, podľa toho, ako bola vykonaná akcia v danom stave vhodná a ako sa v danom kroku priblíži k vytýčenému cieľu. To znamená, že agent dostáva spätnú väzbu priebežne a na základe toho vytvára hodnotovú funkciu, ktorá mu pomáha „odhadnúť“ akciu v nasledujúcom kroku tak, aby viedla k najvyššej celkovej „odmene“.

**Supervised learning** – pri týchto algoritmoch dostane agent vo forme tréningových dát vzory výstupov pre dané vstupy. Úlohu môžeme v tomto prípade formulovať nasledovne: pre danú tréningovú dávku vstupno-výstupných párov  $(x, y)$ , kde každý výstup  $y$  je generovaný neznámou funkciou  $y = f(x)$ , je potrebné nájsť funkciu  $h$ , ktorá aproximuje funkciu  $f$ . Vstupno-výstupné páry  $(x, y)$  môžu byť rôzne veličiny, nemusia to byť číselné hodnoty. Funkcia  $h$  sa nazýva **hypotéza**.

Základná otázka je, ako vieme, že hypotéza  $h$  je vhodná aproximácia funkcie  $f$ , ak túto funkciu nepoznáme? Alebo, koľko príkladov (vstupno-výstupných párov) potrebujeme, aby sme získali dobrú hypotézu  $h$ ? Platí, že každá nevhodná hypotéza sa takmer určite prejaví nesprávnymi predikciami už pri malom počte príkladov. Teda, každá hypotéza, ktorá je konzistentná s dostatočne veľkou sadou tréningových príkladov, musí byť pravdepodobne približne správna (probably approximately correct –

PAC). Každý učiaci algoritmus, ktorý poskytuje pravdepodobne približne správne hypotézy sa nazýva PAC učiaci algoritmus.

Ak je výstup tvorený diskretnými hodnotami (napr. farby, stavy...) učiaci problém sa nazýva **klasifikácia**. Ak sú výstupom čísla, tak učiaci problém sa nazýva **regresia**.

Supervised learning je ilustrovaný príkladom umelej neurónovej siete, ktorý je uvedený vyššie. Hodnoty váh umelých neurónov sú postupne nastavené na také hodnoty, ktoré poskytujú požadované výstupy bez toho, aby sme potrebovali poznať hodnoty (miliónoch) váh jednotlivých neurónov. Z tohto pohľadu sa neurónová sieť javí ako „čierna skrinka“.

Postupne bolo vytvorených viacero algoritmov využívajúcich rôzne postupy hľadania výslednej hypotézy  $h$ , alebo reprezentácie výstupnej naučenej znalosti.

**Rozhodovací strom** patrí k najjednoduchším a pritom účinným algoritmom strojového učenia. Predstavuje funkciu, ktorá z vektoru vstupných hodnôt dosiahne „rozhodnutie“ – jednu výstupnú hodnotu. Výsledná znalosť má formu rozhodovacej procedúry, ktorá má podobu stromu. Rozhodovací strom je pre človeka veľmi prirodzený. Niektoré manuály na opravy sú písané podobným spôsobom.

**Algoritmy generujúce etalóny** – výsledná znalosť má formu typického reprezentanta danej triedy – etalónu. Nový príklad je zaradený do tej triedy, ktorej sa najviac podobá, respektíve ku ktorému má v priestore príkladov najbližšie (Machová, 2010) .

**Pravdepodobnostné modely** - významné postavenie má Bayesovský prístup, kde výsledná hypotéza zohľadňuje doterajšie znalosti (vstupná hypotéza) a nové znalosti vyplývajúce z relevantných dát, ktoré postupne prichádzajú. Prakticky to znamená, že hľadanie riešenia začína predbežnou hypotézou, ktorá vychádza z existujúcich znalostí problému (domény) a množiny hypotéz predstavujúcich pravdepodobnostné teórie vyplývajúce z dát a povahy daného problému (domény). S novými dátami sa postupne aktualizujú pravdepodobnosti jednotlivých hypotéz. Výsledné riešenie je syntézou dvoch rôznych zdrojov informácií: pôvodných znalostí a nových relevantných dát získaných v rámci riešenia danej úlohy. V prípade nadmerných objemov dát a z toho vyplývajúceho veľkého množstva možných hypotéz sú využívané stochastické metódy (Markovove reťazce Monte Carlo - MCMC) vzorkovania multidimenzionálneho priestoru možných hypotéz. Tento postup významne znižuje nároky na rozsah potrebných výpočtových operácií a rozširuje možnosti využitia Bayesovej štatistiky.

To sú niektoré príklady z algoritmov strojového učenia. Medzi ďalšie patria rozhodovacie zoznamy, regresné algoritmy, metóda podporných vektorov (support vector machines), atď. Pri strojovom učení teda vychádzame zo základného predpokladu o podobe funkcie (napríklad polynóm  $k$ -teho stupňa, rozhodovací strom,...), predstavujúcej priestor možných hypotéz a hľadáme konkrétnu verziu funkcie - hypotézu spĺňajúcej PAC kritérium.

### Hotové programové aplikácie strojového učenia

Existujú hotové programové balíky strojového učenia na rôznych platformách (Heller, 2017): **Caffe** je open source platforma pôvodne vyvinutá v UC Berkeley. Obsahuje konvolučnú DNN pre rozpoznávanie obrazcov. Môže mať interfejsy pre Python, Matlab a command-line. **Microsoft Cognitive Toolkit (CNTK)** je rýchly a ľahko použiteľný DNN balík. **MXNet** je prenosná rozšíriteľná DL knižnica, ktorú využíva napríklad DNN Amazonu. Podporuje tvorbu tréningových modelov v R, Python, Scala, C++, JavaScript, Matlab. **Scikit-learn Python framework** je robustná knižnica so širokým výberom algoritmov a integrovanou grafikou. Jej nevýhodou je, že neobsahuje DNN nástroje. **TensorFlow** bol vyvinutý v Google. Je relatívne ľahko nastaviteľný, vhodný aj pre začínajúcich záujemcov o strojové učenie. Obsahuje vizualizačný modul **TensorBoard**, poskytujúci intuitívny pohľad na postup výpočtu. Medzi ďalšie balíky patria Theano, Torch a mnoho ďalších. Viaceré z nich sú voľne prístupné na internete.

Pre tých, ktorí sa chcú bližšie venovať strojovému učeniu, môže byť zaujímavou platforma na prediktívne modelovanie a analýzy **Kaggle** - [www.kaggle.com](http://www.kaggle.com). Obsahuje veľké množstvo datasetov z najrôznejších oblastí, návody a skúsenosti používateľov, ktorí môžu vzájomne súťažiť vo vytváraní najlepších modelov. Výsledky sú verejne zdieľané, aby mohli byť inšpiráciou pre ostatných. Kurz pre začiatočníkov obsahuje podrobný postup pri vytváraní modelu a analýze od počiatočného opisu dát až po výsledné grafické zobrazenia a interpretácie výsledkov.

### **Využívanie systémov strojového učenia**

Ako sme už uviedli, metódy strojového učenia sa veľmi rýchlo rozširujú. Každodennou realitou sú **systémy ponúkajúce produkty a služby**, ktoré nám v mailoch odporúčajú nové dovolenkové destinácie, elektroniku a všeličo iné. Ak nás to obťažuje, môžeme využiť **systémy na detekciu a filtrovanie spamov**. V mobiloch a počítačoch využívame **systémy na rozpoznávanie reči, obrazu** a ďalšie aplikácie. V niektorých oblastiach ľudskej činnosti začínajú mať aplikácie strojového učenia zásadný význam.

V **zdravotníctve** môžu tieto systémy pomôcť poskytnúť presnejšiu diagnózu a zlepšiť rozhodovanie pri ďalšej liečbe. Jedným z príkladov je určovanie diagnózy rakoviny prsníka. Systémy tréňované na snímkach odobraných vzoriek dosiahli pri indikovaní existencie a rozsahu choroby vyššiu presnosť ako patológovia (Beck et al., 2011).

Iným príkladom je diagnóza diabetického oka, ktorá sa vyšetruje posudzovaním zmien očného pozadia spôsobených nemocou. Google vytvoril deep learning algoritmus tréňovaný na datasete 128 tisíc zobrazení očného pozadia, ktoré už boli posúdené lekármi. Systém dokáže diagnostikovať nemoc na úrovni ľudských expertov (Gulshan et al., 2016). Podobný úspech bol dosiahnutý pri diagnostike rakoviny kože (IBM, Watson Health, 2017).

**Transport a logistika** – autonómne vozidlá patria k najpopulárnejším aplikáciám umelej inteligencie. Okrem toho môže byť táto technológia prínosom pri zlepšovaní dopravnej situácie v reálnom čase a pri optimalizácii logistiky.

**Farmaceutický priemysel** – algoritmy strojového učenia dokážu analyzovať štruktúry molekúl možných zložiek liekov a vyhodnocovať, ktoré z nich môžu byť viac, alebo menej účinné (Varnek, Baskin, 2012). Ďalšia aplikácia sa vzťahuje na schopnosť vytvárať na základe dát predpovede o účinkoch liekov na pacientov. Príkladom sú predikcie odozvy pacientov na rôzne lieky pre liečenie depresie (PReDicT, 2017).

**Financie** – strojové učenie sa využíva vo financiách už v súčasnosti, napríklad v systémoch na zachytenie neobvyklých aktivít a transakcií na účtoch. Sú vyvíjané ďalšie spôsoby jeho využitia na zvýšenie bezpečnosti a zjednodušenie prístupu klientov k svojim účtom.

**Energetika** – strojové učenie môže byť využité na optimalizáciu energetickej infraštruktúry na základe analýzy režimu spotreby energie, hlavne v energetických špičkách. Napríklad Google DeepMind to využil na optimalizáciu ohrevu a chladenia svojich datacenter predikciou teplôt a tlakov. To umožnilo znížiť spotrebu na chladenie o 40% (Google, DeepMind (2016)).

**Výskum a vývoj** – pri detekovaní nových častíc pri experimentoch Veľkého hadrónového urýchľovača v CERN pri kolíziách vysoko energetických častíc vznikajú produkty zrážok, ktorých životnosť je veľmi nízka – Higgsov bozón zaniká za  $10^{-22}$  sekundy. Nájdenie takýchto častíc v okamihu zrážky vyžaduje špeciálne metódy detekcie, pri ktorej sa využíva strojové učenie (Castelvecchi, 2015).

Hlavnou výzvou pre **astronómov** je zaznamenať zaujímavé útvary a signály, oddeliť ich od šumu a priradiť do správnych kategórií, alebo javov. Napríklad pri spracovaní dát z misie Kepler (Roberts et al., 2013), identifikácii nových pulzarov z existujúcich datasetov (Morello et al., 2014), určovaní vlastností hviezd (Miller et al. 2015) a supernov (Lochner et al., 2016). Očakáva sa, že Veľký celooblohový teleskop – Large Synoptic Survey Telescope (LSST) vytvorí v nočných snímkach oblohy 15 terabyte astronomických dát každú noc (LSST, 2017). Strojové učenie pomáha v týchto analýzach pri príprave dát a tiež pri detekcii zaujímavých úkazov v dátach.

## „Big data“ a strojové učenie.

Už bolo uvedené, že jedným z impulzov novej vlny rozvoja umelej inteligencie bola existencia označených datasetov, ktoré začali byť generované ako súčasť rozvoja internetu a sociálnych sietí. Podľa The Royal Society (2017) sa 90 percent svetových dát vytvorilo za posledných päť rokov a nové zdroje dát pribúdajú stále rýchlejšie. Tieto dáta predstavujú v globálnej ekonomike obrovskú hodnotu (Manyika et al., 2013), samozrejme len v prípade, ak budú vhodným spôsobom spracované. Komplexnosť zdrojov a obrovské množstvo dát vyžadujú nové prístupy a metódy analýzy. Paralelne s explozívnym nárastom dát sa tak na scéne objavili nové nástroje na ich spracovanie a využitie - systémy strojového učenia.

## Strojové a ľudské učenie – rozpoznávanie vzorov verzus vytváranie modelu

Princípy algoritmov strojového učenia uvedené v predchádzajúcom texte nám dovoľujú nadviazať na úvahy z úvodnej časti tohto článku o mechanizmoch poznávania a porovnať strojové učenie s tým ľudským.

### Rozpoznávanie vzorov

Metódy strojového učenia dosahujú pri klasifikácii objektov výsledky porovnateľné s ľudskými. To však neznamená, že sa učia a rozmyšľajú ako človek. Sú špecializované na určité kategórie úloh, ale v ostatných smeroch za ľudským učením ďaleko zaostávajú. Hľadanie najlepšej hypotézy v zmysle strojového učenia spočíva v štatistickom rozpoznávaní vzorov a primárnym cieľom je **predikcia**, obvykle v kontexte úlohy spočívajúcej v klasifikácii, alebo regresii. Z tohto hľadiska je učenie hľadaním podobných hodnôt stavov umožňujúcich zaradenie do skupín podľa nastavenej klasifikácie. Podmienkou úspešného výsledku sú potrebné rozsiahle dávky rôznorodých tréningových dát. Na druhej strane, schopnosť spracovať obrovské množstvá generovaných dát robí zo strojového učenia vynikajúceho pomocníka.

### Vytváranie modelu vonkajšieho sveta

Existuje aj iný prístup, kde učenie je založené na vytváraní modelu vonkajšieho sveta. Učenie znamená budovanie tohto modelu a poznávanie spočíva v jeho využívaní pri pochopení toho, čo sa okolo nás deje, pre **vysvetlenie** vnímaných skutočností a prípadnom plánovaní reakcií na daný stav. Rozdiel medzi **rozpoznávaním vzorov** a **vytváraním modelu**, medzi predikciou a vysvetľovaním je kľúčovou odlišnosťou umelej a ľudskej inteligencie.

Je až udivujúce ako rýchlo dokážeme rozpoznať novú situáciu, v zlomku sekundy pochopiť scénu, ktorú vidíme a prípadne aj konať. Ľudia sa dokážu naučiť oveľa viac z oveľa menšieho počtu príkladov, pretože využívajú model, ktorý si od narodenia budujú. Nová okolnosť, stav, vyriešený problém znamená nielen použitie existujúceho modelu (asimilácia), ale zároveň aj jeho doplnenie (akomodácia) (Piaget, 1997). Prirodzenou črtou tohto postupne vytváraného modelu je jeho štruktúrovanosť, ktorá umožňuje skladať zložité reprezentácie z jednoduchších prvkov. Ďalším dôležitým komponentom modelu je využívanie príčinných súvislostí (kauzalita). To znamená nielen vnímať objekty na scéne, ale chápať kauzálne stavy medzi objektmi. Napríklad sily, ktoré medzi nimi pôsobia a môžu viesť ku zmene ich usporiadania. Štruktúrovanosť a kauzalita podmieňujú využívanie analógií pri vytváraní bohatších, univerzálnejších modelov a generovaní nových príkladov na základe jediného vzoru nejakého nového konceptu.

## Umelá inteligencia, všeobecná umelá inteligencia a super inteligencia

Rozvoj umelej inteligencie nastoľuje stále nové výzvy a otázky nielen pri rozvíjaní jej základných princípov a efektívnom využívaní aktuálnych výsledkov, ale aj pri posudzovaní budúcich možných dôsledkov ďalšieho vývoja inteligentných systémov.

Zabudovanie štruktúrovanosti<sup>3</sup> a kauzality (Lake et al., 2016) pri budovaní modelov umelej inteligencie by znamenalo posun k umelej všeobecnej inteligencii „Artificial General Intelligence (AGI)“, ktorá je v súčasnosti samostatnou podoblasťou AI. Zameriava sa na hľadanie všeobecného algoritmu poznávania a konania v rôznych prostrediach. Na rozdiel od umelej inteligencie, ktorá, ako bolo uvedené vyššie, sa orientuje na riešenie špecifických úloh, všeobecná umelá inteligencia sa snaží vytvoriť stroj, ktorý má univerzálne schopnosti riešiť intelektuálne úlohy a konať ako človek.

To je však podľa niektorých autorít začiatok celkom novej situácie – vzniku umelej super inteligencie. Najvyššia forma umelej inteligencie „Artificial Super Intelligence (ASI)“ je umelý intelekt, ktorý je oveľa lepší než človek (Bostrom, 2014). Je ťažké predpovedať ako dlho potrvá, kým sa úroveň umelej inteligencie priblíži ľudskej úrovni. Podľa uvedených autorít však možno očakávať, že ďalší krok k super inteligencii bude oveľa rýchlejší. Scenár vzniku tzv. „singularity“ predpokladá, že určitá dostatočne pokročilá a ľahko modifikovateľná umelá inteligencia („zárodočná“) aplikuje svoje schopnosti na vytvorenie zlepšenej vlastnej kópie. Zlepšená verzia vytvorí ešte dokonalejšiu vlastnú kópiu. Takýto cyklický proces povedie k explózii inteligencie. Je otvorenou otázkou, čo to bude znamenať pre ľudstvo (Bostrom, 2014). Možné sú pozitívne, ale aj negatívne smery vývoja a osud človeka môže závisieť od toho, aké počítačové podmienky vložil do „zárodočnej“ verzie. V januári 2015 podpísalo viacero osobností, vrátane Stephena Hawkinga a Elona Muska, otvorený list, v ktorom označili pokročilú umelú inteligenciu za „najväčšiu existenciálnu hrozbu“ a upozorňovali na možné ohrozenie ľudskej rasy. Väčšina počítačových vedcov však považuje dané výzvy v najlepšom prípade za „neinformované“.

---

<sup>3</sup> Zaujímavý krok v tomto smere je uvedený správe **Bonsai Sets State-of-the-Art Reinforcement Learning Benchmark for Programming Industrial Control Systems** z 19. septembra 2017, predstavujúcu koncepčné siete. V danom príklade bola zložitá robotická úloha, spočívajúca v premiestnení hranola z pôvodného miesta na kocku, rozdelená na niekoľko jednoduchších úkonov: dosah, orientácia ruky, uchopenie, presun a uloženie hranola na nové miesto. Trénovaním jednoduchších úkonov samostatne a následné spojenie do výsledného riešenia znamenalo významné skrátenie doby učenia. <https://bons.ai/blog/rl-benchmark>.

## Referencie

- Beck, A. et al. (2011): Systematic analysis of breast cancer morphology uncovers stromal features associated with survival. *Sci. Transl. Med* 3 108.
- Bonawitz, E., Denison, S., Griffiths, T. L. & Gopnik, A. (2014): Probabilistic Models, Learning Algorithms, and Response Variability: Sampling in Cognitive Development. *Trends in Cognitive Sciences*, 18 p. 497-500.
- Bostrom, N. (2014): *Superintelligence – Paths, Dangers, Strategies*. Oxford University Press.
- Castelvecchi D. (2015): Artificial intelligence called in to tackle LHC data deluge. *Nature* 528, 18. (doi: 10.1038/528018a).
- Farkaš, I. a kol. (2013): Kognitívna veda a umelá inteligencia. Projekt "Informační, kognitivní a interdisciplinární podpora výzkumu" (reg. č. CZ.1.07/2.3.00/20.0001), 2013.
- Google. DeepMind (2016). Press release: DeepMind AI reduces Google data centre cooling bill by 40%. See <https://deepmind.com/blog/deepmind-ai-reduces-google-data-centre-cooling-bill-40/> .
- Gulshan, V. et al. (2016): Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photograph. *JAMA* 312.
- Heller, M. (2017): Review: The best frameworks for machine learning and deep learning. Infoworld <<http://www.infoworld.com/article/3163525>>
- IBM Watson Health. (2017): <<http://www.ibm.com/watson/health/oncology>>
- Kováč, L. (2000): Fundamental Principles of Cognitive Biology. *Evolution and Cognition* 6 p. 51-69.
- Lake, B. M., Ullman, T.D., Tenenbaum, J.B. and Gershman, S. J. (Nov. 2016): Building Machines That Learn and Think Like People. *Behavioral and Brain Sciences*.
- Lochner, M., McEwen, J.D., Peiris, H.V., Lahav, O., Winter, M.K. (2016): Photometric supernova classification with machine learning. *Astrophys. J. Suppl. Ser.* 225, 31.
- LSST (Large Synoptic Survey Telescope). <<https://www.lsst.org/>>
- Machine learning: the power and promise of computers that learn by example. The Royal Society, London, April 2017.
- Machová, K. (2010): *Strojové učenie v systémoch spracovania informácií*. Technická univerzita Košice, 2010.
- Manyika, J., Chui, M., Farrell, D., van Kuiken, S., Groves, P., Doshi, E. (2013): *Open data: unlocking innovation and performance with liquid information*. McKinsey Global Institute.
- Miller, A. et al. (2015) : A machine learning method to infer fundamental stellar parameters from photometric light curves. *Astrophys. J.* 798, 17.
- Morello, V., Barr, E.D., Bailes, M., Flynn, C.M., Keane, E.F., van Straten, W. (2014): SPINN: a straightforward machine learning solution to the pulsar candidate selection problem. *Mon. Not. R. Astron. Soc.* 443, 1651–1662.
- Piaget, J. (1997): *Development and learning*. In: Gauvain M. & Cole G. M. (eds.) *Readings on the development of children*. Second Edition. W. H. Freeman, New York: 19–28.
- PREdicT (Predicting Response to Depression. Treatment). See <http://predictproject.p1vitalproducts.com/> (accessed 22 March 2017).
- Roberts, S., McQuillan, A., Reece, S., Aigrain, S. (2013): Astrophysically robust systematics removal using variational inference: application to the first month of Kepler data. *Mon. Not. R. Astron. Soc.* 435, 3639–3653.

Rojas, R.(1996): Neural Networks. Springer-Verlag, Berlin.

Russel, S., Norvig, P. (2010): Artificial Intelligence a Modern Approach, Third Edition. Prentice Hall.

The MITRE Corporation, (2017): Perspectives on Research in Artificial Intelligence and General Intelligence Relevant to DOD. OSD ASDRE&E Basic Research Labs, Alexandria VA.

The Royal Society (2017). Learning infographic: what is machine learning?

<https://royalsociety.org/topics-policy/projects/machine-learning/machine-learning-infographic/>

Varnek, A., Baskin I. (2012): Machine learning methods for property prediction in chemoinformatics: quo vadis? J. Chem. Inf. Model. 52, 1413–1437.