



Umělá inteligence

Gerstnerova laboratoř
Katedry kybernetiky


Umělá inteligence

Studium inteligence: jak vnímáme svět, jak chápeme svět, jak předvídáme následky svých akcí ve světě, jak svět ovlivňujeme

Umělá inteligence chce nejen porozumět inteligenci, ale i

- vytvořit inteligentní entitu (agenta, robota)
- napodobující* nebo *vylepšující*
- pouze lidské *chování a projevy*, nebo i *myslenkové procesy a uvažování*.

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60 61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80 81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99 100

Umělá inteligence I. 

Ideální agent: požadavky

Reprezentace znalostí:

- jak uložit model světa, relací mezi entitami, které v něm vystupují, pravidel, které v něm platí

Automatické uvažování:

- jak z modelu světa odvodit závěry, odpovědi na otázky

Plánování:

- jak najít sekvenci akcí, která uvede svět do žádaného stavu


Strojové učení:

- jak přizpůsobit model světa novým pozorováním, jak z nových pozorování odvodit novou hypotézu

Multiagentní systémy:

- jak koordinovat činnost a kooperovat ve skupině agentů

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60 61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80 81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99 100

Umělá inteligence I. 

Ideální agent: požadavky (pokr.)

Zpracování přirozeného jazyka:

- zpracování signálu (převod zvuku na písmena, slova)
- porozumění významu slov, převod do jazyka reprezentace znalostí o světě


Počítačové vidění:

- zpracování a porozumění obrazu, jaké entity pozorujeme, jaký vztah mezi nimi obraz (sekvence obrazů) zachycuje

Robotika:

- manipulace s objekty, pohyb, taktilní senzory
- navigace a lokalizace

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60 61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80 81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99 100


Umělá inteligence I. 

Agent a robot

Zaměnitelné pojmy označující systémy s různým stupněm autonomnosti podle schopnosti „předvídat“ projevy světa a důsledky svých zásahů do něj. Někdy ale:

Agent: především softwarová část realizující inteligenci

Robot: především technické zařízení, jehož účelem je *zastoupit* člověka, např. při průzkumu míst, kam se člověk nedostane (*špatná přístupnost*: Mars, *riziko*: místo katastrofy, *rozměry*: laparoskopická operace, ...), při rutinní opakované činnosti...




Domácí úkol

Oznámkuje následující roboty z hlediska „množství inteligence“, kterou obsahují, na škále 0 – 10 (0 nejméně, 10 nejvíce). U každého z nich zkuste definovat, jak podle vás uvnitř fungují a jaké „rasy inteligence“ podle vás obsahují.

- Robotický vysavač Roomba
- Pyrotechnický robot pro zneškodňování bomb
- Svařovací robotické rameno v karosárně automobilky
- Robotičtí průzkumníci na Marsu

Vypracujte krátký dokument v PDF a odevzdejte jej do upload systému.

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60 61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80 81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99 100

Umělá inteligence I. 

Osnova přednášek v návaznosti na KUI:

1. **Strojové učení** - Metody klasifikace a rozhodovací stromy. Weka. *Bayesovské a nebayesovské úlohy*.
2. Adaboost, SVM klasifikátory
3. Grafické pravděpodobnostní a Markovovské modely ve strojovém učení
4. Teorie učení - problémy konzistence, kapacity, PAC
5. Učení klasifikačních pravidel (AQ, CN2)
6. Sekvenční rozpoznávání, Waldův algoritmus, extrakce a syntéza příznaků, vlastnosti
7. - 8. **Plánování.**
9. - 12. **Multiagentní systémy**
13. **Umělý život**

Strojové učení Machine learning (ML)

Osnova

- Strojové učení nejen pro robotiku
- Konstrukce rozhodovacího stromu
- Otázky související se strojovým učení
- Ukázka aplikace

Učení z příkladů

Učení je zlepšování výkonnosti (úspěšnosti) systému při řešení úloh stejného typu na základě pozorování světa.

Učení z příkladů je jeden konkrétní typ učení: na základě množiny párů vstupů a výstupů vytvoří funkci, která bude na základě vstupů předvídat výstupy i pro nová data

Proč je učení nutné?

- tvůrci agenta nemohou předvídat *všechny možné situace a všechny možné změny světa v čase*
- někdy tvůrci agenta sami nevědí, jak řešení úlohy vypadá: žádný ručně napsaný program dosud neumí dobře na fotkách rozeznávat obličeje; modely naučené metodami strojového učení to umí.

Problémy v robotice řešené učením

1. Mapování z prostoru stavů agenta na akce.
2. Vlastnosti reálného světa z informací ze senzorů.
3. Informace o způsobu evoluce světa a o tom, jak se v něm projeví možné akce agenta.
4. Užitek, který plyne z jednotlivých stavů světa.
5. Užitek, který plyne z akcí, které agent může provést.
6. Cíle (třídy stavů světa), jejichž dosažení maximalizuje agentovu užitečnost.

Příklad

Agent se snaží stát se dobrým řidičem taxi.

1. Kdyžkoli instruktor zakřičí „Brzdi!“, agent si vytvoří pravidlo mapující stav světa na akci. (Učí se, i když instruktor nekřičí?)
2. Z mnoha obrázků autobusů se naučí rozeznat autobus ve videosignálu.
3. Pozorováním výsledků svých akcí („Prudce zabrzdí na mokré silnici“) se naučí efekty svých akcí na svět, příp. detailnější modely: (stav silnice, rychlost, intenzita brzdění) → brzdná dráha.
4. Nedostane-li dýško od pasažérů, protože s nimi nejel šetrně, může se naučit jistou část ze své funkce užitečnosti.

Další (nerobotické) úlohy pro ML

Dobývání znalostí z dat s použitím technik ML

- Záplava vznikajících dat v el. formě:
 - obchodní a bankovní transakce,
 - služby (spotřeba energie/vody ... u odběratelů, pohyb vozů, ...)
 - lékařské záznamy (medikace pacientů, rodinná anamnéza, snímky v různých vývojových fázích, ..),
 - vědecko-technická data (data projektu Human Genome, geografické snímky, záznamy o provozu a poruchách technických zařízení, astronomická data, ..)
 - Přístupy na web stránky, ...
- Otázky: zefektivnění provozu, prediktivní diagnostika, detekce zajímavých snímků/oblastí, ..
- **Odpovědi nelze hledat ručně:** automatizace pomocí **ML**

16 / 23 Umělá inteligence I. 

Další (nerobotické) úlohy pro ML (pokr.)

- Tvorba **SW aplikací pro velmi složité prostředí**, kde „neumíme popsat algoritmus řešení“, ale můžeme nabídnout příklady konkrétních řešení (řízení auta/ letového simulátoru, vyhodnocování rtg. snímků, rozpoznávání řeči, ...)
- **Adaptace technologie** na měnící se prostředí úlohy
- Tvorba **individuálních technologických řešení** splňujících omezující podmínky dané zákazníkem: individualizovaný web zpravodaj, SW agenti pro hledání v síti, ...
- **Automatické programování** (třeba v Prologu), **hledání programových invariantů** pro dokazování správnosti programů, ...
- ...

17 / 23 Umělá inteligence I. 

Typy učení podle zpětné vazby

Bez učitele (unsupervised learning): bez zpětné vazby, identifikace vzorů a pravidel ve vstupních datech. Zahrnuje *shlukování, modelování pravděpod. rozdělení, asociační pravidla, odvozování nových atributů*. (Taxi agent: tvorba konceptů „dny s hustou dopravou“, „dny s řídkou dopravou“.)

Učení posilováním (reinforcement learning): agent se učí z odměn/penalizací z vnějšího světa, jež jsou následkem sekvence předchozích akcí. Je na agentovi, aby zjistil, které akce jsou hlavní příčinou. (Malé dýško může být signál, že agent udělal něco špatně.)

S učitelem (supervised learning): přímé učení funkce mapující vstupy na výstupy. (Instruktor křičící „Brzdi!“ poskytuje výstup ke vstupům představovaným stavem světa a všemi vjemy agenta.)

18 / 23 Umělá inteligence I. 

Učení s učitelem

Trénovací data: $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$,
Každé $y_i = f(x_i)$, f neznáme.

Cíl: vytvořit funkci h (**hypotézu, model**), která dobře aproximuje f , a to i na nových příkladech, které nejsou v T .

Učení: prohledávání prostoru hypotéz


Testovací data: na T nezávislá sada dat ze stejného zdroje, potřebná k měření přesnosti modelu

Generalizace: říkáme, že hypotéza dobře generalizuje, pokud poskytuje kvalitní predikce y i pro nové příklady

Klasifikace: y je nominální, binární: y nabývá pouze 2 hodnot

Regrese: y je spojitá

V několika dalších přednáškách: především učení s učitelem

19 / 23 Umělá inteligence I. 

Doporučená literatura

- Tom M. Mitchell: **Machine Learning**, McGRAW HILL INT. EDITIONS 1997
- Russel Stuart, Peter Norvig: **Artificial Intelligence: A Modern Approach**,
- V. Mařík a kol.: **Umělá inteligence 1-5**, Academia 1993-2007
- P. Berka: **Dobývání znalostí z databází**, Academia 2003

20 / 23 Umělá inteligence I. 