

Modelování myšlení

Radek Pelánek

Tento projekt je spolufinancován Evropským sociálním fondem a státním rozpočtem České republiky.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Myšlení, modelování, počítače

(zjednodušené, plynulý přechod)

kognitivní modelování

- cíl: zachytit, jak funguje mysl
- důraz na jednoduchost, věrnost, principy
- není úplně zásadní „výkon“

umělá inteligence

- cíl: reprodukovat inteligentní chování
- důraz na „výkon“
- biologické principy jen jako inspirace

Kognitivní modelování

symbolické modelování

- „high-level“
- uvažování na úrovni pravidel, metafora počítače
- manipulace symbolů

konekcionistické modelování

- „low-level“
- uvažování na úrovni neuronů
- snaha o biologickou věrnost

Porozumění mozku

Kdyby byl mozek tak jednoduchý, že bychom mu mohli rozumět, byli bychom tak jednoduší, že bychom nemohli.
(Lyaal Wattson)

Symbolické modelování

- *computational theory of mind*
- myšlení jako manipulace symbolů
- produkční pravidla: IF X THEN Y
- učení: vytváření nových pravidel (např. spojováním, vyhledáváním)
- kde se vezmou symboly?

Produkční systém

- pravidla typu
IF podmínka THEN akce
- podmínky přichází z prostředí nebo jako následky jiných pravidel
- akce mohou vyvolávat další pravidla nebo měnit prostředí

Příklad:

IF chci čaj THEN uvařit čaj

IF uvařit čaj a nemám horkou vodu THEN dát vodu do konvice

Produkční systémy: kolize


- pravidla mohou být **kolizní** (nedeterministický systém)
- pro danou situaci výběr aplikovatelných, rozhodnutí kolize
- priority, náhoda, ...

Příklad:

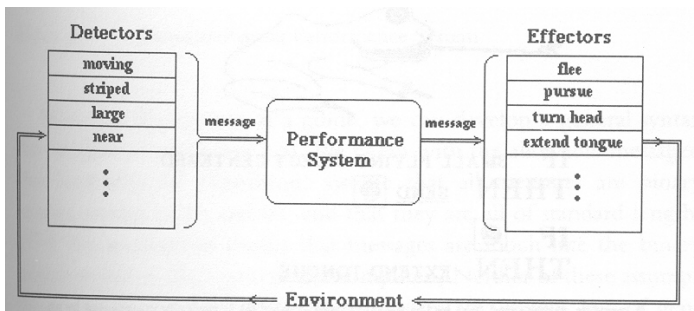
IF chci čaj THEN uvařit čaj

IF chci čaj THEN zajít do hospody a objednat čaj

Příklad žába: základní princip




(John Holland, Hidden Order: How Adaptation Builds Complexity)

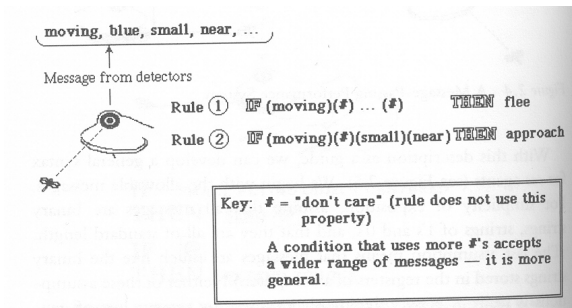


(John Holland, Hidden Order: How Adaptation Builds Complexity)

Příklad žába: produkční systém




Příklad žába: výběr použitelných pravidel



(John Holland, *Hidden Order: How Adaptation Builds Complexity*)

Příklad žába: řešení kolize



(John Holland, *Hidden Order: How Adaptation Builds Complexity*)

Klasifikační systémy

(Learning classifier systems)

Konkrétní příklad architektury:

- 1 produkční systém
- 2 ohodnocení pravidel (bucket brigade)
- 3 objevování pravidel pomocí genetického algoritmu

Ohodnocení pravidel: bucket brigade

- pravidla konfliktní
- pravidlo má **kapitál**
- výběr pravidla podle aktuálního kapitálu
- pravidlo **platí** za to, že může být použito
- úspěšná aplikace \Rightarrow zisk **odměny** od prostředí
- část odměny **redistribuována** pravidlům, které umožnily použití pravidla, které vedlo k odměně

Vývoj nových pravidel

- pravidla jsou reprezentována jako binární řetězce
- přímočaré použití genetického algoritmu
- zdatnost = kapitál

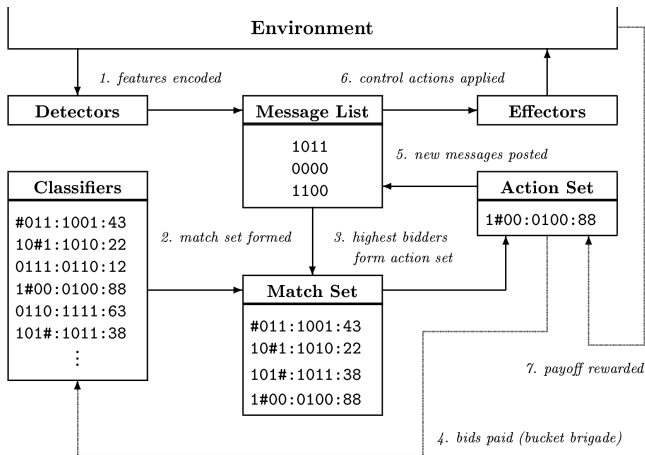


Figure 21.2 A classifier system interacting with its environment

(G. W. Flake, *The Computational Beauty of Nature*)

Příklad Woods

- (podobné jako Robby the Robot u gen. alg.)
- zvíře na čtverečkováném poli
 - '*' zvíře
 - '.' volné pole
 - 'O' skála
 - 'F' jídlo
- zvíře vidí okolních 8 pozic, tj. detektory lze zakódovat pomocí 16 bitového řetězce (. = 00, O = 10, F=11)
- cílem je najít co nejrychleji jídlo

Příklad Woods

```

.....
.00F..00F..00F..00F..00F..00F..00F..00F..00F..00F..
.000..000..000..000..000..000..000..000..000..000..
.000..000..000..000..000..000..000..000..000..000..
.....
.....
.00F..00F..00F..00F..00F..00F..00F..00F..00F..00F..
.000..000..000..000*.000..000..000..000..000..000..
.000..000..000..000..000..000..000..000..000..000..
.....
.....
.00F..00F..00F..00F..00F..00F..00F..00F..00F..00F..
.000..000..000..000..000..000..000..000..000..000..
.000..000..000..000..000..000..000..000..000..000..
.....

```


(G. W. Flake, *The Computational Beauty of Nature*)

Příklad Woods

Realizace experimentu (učení):

- náhodně umístit zvíře
- nechat běžat dokud nenajde jídlo
- a pak znova od začátku

Příklad Woods: výsledky



(G. W. Flake, *The Computational Beauty of Nature*)

Příklad Woods: složitější prostředí


```

.....0......00.....0.....
.OFO.....F.....F.....0.....F.....FO.....
.....0.....00.....F.....
.....0.....0.....F.....0.....
...F.....OFO.....OFO.....F.....00.....F...
...00.....0.....
.....00.....0.....00.....0.....
.OFO.....F.....OF.....F.....OFO.....F.....
.....0.....
...00.....0.....0.....00.....0.....
...F.....F.....0.....FO.....F.....OF...OFO.
.....0.....OF.....
...0.....F.....0.....0.....0.....0...
...F.....F.....F.....FO.....F.....OF...
...0.....00.....0.....0.....
.....0.....0.....
...F.....OFO.....F.....F.....F.....OF.....
...00.....0.....00.....0.....0.....

```

(G. W. Flake, *The Computational Beauty of Nature*)

Příklad Woods: výsledky II



(G. W. Flake, *The Computational Beauty of Nature*)

Deduktivní a induktivní uvažování

- **deduktivní** uvažování
 - z daných předpokladů se dle zákonů logiky odvozují logicky platné závěry (konkretizace)
 - modelování není velký problém (deduktivní uvažování lze vyjádřit formálně), hojně používáno např. v ekonomii
 - ovšem neodpovídá realitě – lidé používají deduktivní uvažování jen v omezené míře
- **induktivní** uvažování
 - zevšeobecňování, odvozování obecných zákonů z konkrétních příkladů, odhadování vývoje, ...
 - často a úspěšně používáno lidmi
 - jak modelovat?

El Farol Bar

El Farol je bar v Santa Fe, kde hrají ve čtvrtek večer irskou hudbu

- v okolí baru žije 100 lidí
- každý by rád zašel do baru, ale když je tam moc narváno, tak to za nic nestojí:
 - v baru méně jak 60 lidí \Rightarrow lepší být v baru než doma
 - v baru více jak 60 lidí \Rightarrow lepší být v doma než v baru
- všichni se **rozhodují současně**, žádná domluva

Deduktivní model rozhodování

deduktivní řešení:

- „hodit si kostkou“, tj. rozhodovat se náhodnostně podle vypočítané pravděpodobnosti
- tak se ale lidé nerozhodují...

Induktivní model rozhodování

Každý agent má několik **hypotéz** pro předpovídání počtu návštěvníků. Příklad dosavadní sekvence a hypotéz:


44, 78, 56, 15, 23, 67, 84, 34, 45, 76, 40, 56, 22, 35

- stejně jako minulý týden [35]
- zaokrouhlený průměr za minulé 4 týdny [49]
- stejně jako před dvěma týdny [22]
- zrcadlový obraz okolo 50 z minulého týdne [65]
- 42 [42]

Induktivní model rozhodování

- pro každou hypotézu si agent pamatuje její **úspěšnost**
- vždy se rozhoduje podle aktuální nejúspěšnější hypotézy (případně průměruje několik nejúspěšnějších)
- hypotézy vygenerovány „ručně“, každému agentu náhodně přiřazeno několik z nich

Simulace



Výsledky a rozšíření

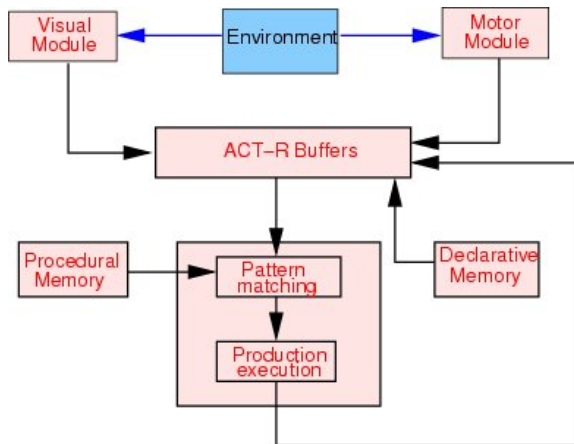
- počet návštěvníků osciluje okolo hodnoty 60
- induktivně uvažující agenti tedy řeší problém poměrně dobře
- možná rozšíření: tvorba nových hypotéz (genetický algoritmus), komunikace mezi agenty, ...

ACT-R (Adaptive Control of Thought–Rational)

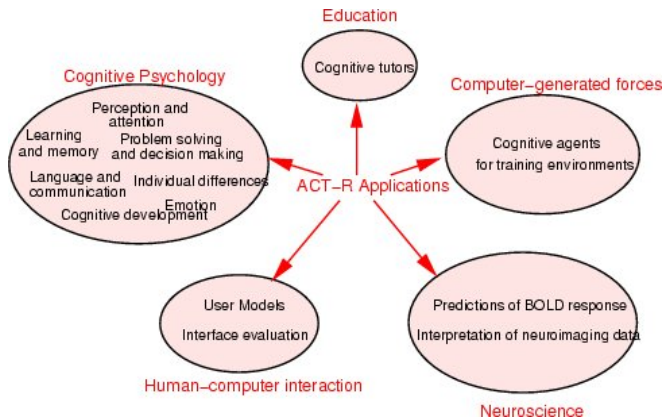
- kognitivní architektura
- založeno na produkčních systémech
- rozsáhlé, mnoho aspektů vnímání, myšlení, paměti
- mnoho aplikací

<http://act-r.psy.cmu.edu/>

ACT-R (Adaptive Control of Thought–Rational)



ACT-R: aplikace



Aplikace ve výuce

- inteligentní výukové systémy
- produkční systém pro určitou oblast (např. aritmetika)
- model „sleduje“ řešení studenta \Rightarrow ohodnocení schopností studenta, identifikace silných/slabých míst
- pravidla pro typické chyby \Rightarrow možnost cílené zpětné vazby

Neuronové sítě

- model založený na zjednodušené imitaci fungování mozku
- neurony, spojení
- **induktivní učení** prostřednictvím trénovacích dat
- „znalosti“ jsou v síti uloženy jako váhy **spojení** mezi neurony

Neuron





Figure 18.1 A “typical” neuron with major components identified

(G. W. Flake, *The Computational Beauty of Nature*)


Model neuronu




$$a(t + 1) = \Phi\left(\sum_{i=1}^n w_i \times a_i(t) - b\right)$$

Model neuronu: aktivační funkce

diskrétní aktivační funkce



spojitá aktivační funkce




Umělá neuronová síť

... připomíná reálnou neuronovou síť:

- neurony spojené váženými vazbami
- schopná se učit na základě předkládaných dat
- „znalosti“ uloženy jako váhy spojení mezi neurony


Příklad architektury – dopředná síť



• **Stressors** are the environmental factors that cause stress.

- předkládáme sadu příkladů: vstup + žádaný výstup
- upravujeme váhy spojení mezi neurony (např. backpropagation algoritmus)
- učení = korigující negativní zpětná vazba

Příklad architektury – zpětnovazební síť



Zpětnovazební síť

- zpětnovazební síť – obsahuje cykly
- modelování asociativní paměti
 - vězeň, dramatik, prezident
 - kd jinm jmu kop sm do n pad
- Hebbův zákon učení:
dva neurony aktivovány ve stejnou chvíli \Rightarrow posílení spojení

Rozpoznávání znaků




Figure 18.3 Bitmapped images of letters from the alphabet: The first three are clean version that are used as patterns to be stored. The last three are used as seed images that the associative memory must use to recall one of the first three.

(G. W. Flake, The Computational Beauty of Nature)

Řešení optimalizačního problému




Figure 18.6 The task assignment problem: Black squares in the entries denotes the optimal assignment with a total shelving rate of 44.

Řešení optimalizačního problému



Figure 18.7 Computing a neural solution to the task assignment problem: This particular solution yields a total rate of 42, which is just less than the optimal solution.

(G. W. Flake, *The Computational Beauty of Nature*)

Vývoj sdíleného slovníku

- model **vytváření sdíleného slovníku** ve skupině agentů
- agenti si vytváří slovník pro objekty, pojmenování je reprezentováno pomocí neuronové sítě
- interakce = agenti si vymění svoje názory na název objektu, trochu se přeučí
- díky interakci vzniká sdílený slovník

Příklady aplikací

- klasifikace vzorů, např.
 - rozpoznávání jazyka dokumentu podle frekvencí písmen
 - rozpoznání čisté a naředěné malinové hmoty dle infračerveného spektra
- rozpoznávání obrazů, řeči
- aproximace funkcí, predikce řad
- zpracování dat
- hry, rozhodování

Deep learning

žhavé téma v oblasti neuronových sítí


dopředná síť, mnoho úrovní:

- úrovně mohou sloužit jako „stupně abstrakce“ (feature learning)
- problém: náročné síť naučit
- možné řešení: „předučení“, vždy dvě úrovně za sebou, „auto-encoder“

stručný úvod: Andrew Ng – Deep Learning, Self-Taught Learning and Unsupervised Feature Learning

<https://www.youtube.com/watch?v=n1ViNeWhC24>

Kočky na YouTube



http://research.google.com/archive/unsupervised_icml2012.html

<http://www.nytimes.com/2012/06/26/technology/>

[in-a-big-network-of-computers-evidence-of-machine-learning.html](http://www.nytimes.com/2012/06/26/technology/in-a-big-network-of-computers-evidence-of-machine-learning.html)

Poznámky k neuronovým sítím

- smysluplné využití neuronových sítí – náročné
- jako projekt nemá smysl
- pro zájemce:
 - kurzy strojového učení
 - PV021 Neuronové sítě

Shrnutí

- účel modelování myšlení:
 - pochopení, jak myšlení funguje
 - zlepšení modelů (s agenty)
 - aplikace pro řešení „inženýrských“ problémů
- typy modelů:
 - symbolické
 - konekcionistické
 - hybridní (neprobíráno)