

Ako merať „kogníciu“

Andrej Lúčny

Katedra aplikovanej informatiky, Fakulta matematiky, fyziky a informatiky, Univerzita Komenského
Mlynská Dolina, 812 19 Bratislava
lucny@fmph.uniba.sk

Abstrakt

Ukážeme ako je možné použiť Shannonovu teóriu informácie na určitý popis poznávacích schopností systému (napr. robota). Hlavnou myšlienkou tohto popisu je sledovanie neurčitosti informácií o prostredí, ktoré systém využíva pri voľbe vlastných akcií. Túto neurčitosť je možné merať na základe informačnej entropie týchto informácií v porovnaní s prostredím, ktoré chápeme ako ich zdroj. Tento prístup sa vyznačuje aj problémami, ktoré uvádzame (dynamické prostredie, fantomické informácie). Na základe spomínanej schémy potom navrhujeme určitú klasifikáciu poznávacích schopností. Na záver uvažujeme ako sa dá náš prístup uplatniť v rámci dlhodobej evolúcie systémov. Tú možno chápať ako dlhodobé zlepšovanie poznania ich životného prostredia.

1 Úvod

Je veľa definícií kognície¹ a sú vzájomne tak rôzne, že to vzbudzuje dojem, že tento pojem je tzv. „buzzword“. Existuje viacero prístupov ako zúžiť a presne vymedziť tento pojem, z filozofického hľadiska oveľa ambicióznejších než náš ([5][7]), nie je nám však známe, že by dosiahli takú detailnosť, aby sa dali formalizovať. Nič menej pokiaľ zúžime pojem kognície na schopnosť systému poznať a poznávať svoje prostredie, dá sa navrhnúť celkom objektívny spôsob ako tento fenomén merať. Náš prístup je založený na klasickej Shannonovej teórii informácie [6], hlavne na pojme zdroja informácie. Inšpirujeme sa pritom kognitívnou biológiou [3]. Svoj výklad sa však pokúsime podať samonosne.

Podstatný detail v našom prístupe spočíva v tom, že sa obmedzíme na tú časť systému, ktorá hromadí informáciu o prostredí, užitočnú v tom zmysle, že systém na ňu prihliada pri voľbe svojich akcií (Fig 1.). Hoci reálne sa percepčná a akčná časť prelínajú, spomínanú užitočnú informáciu je možné rozumne zvoliť, pokiaľ poznáme vnútornú štruktúru systému. Nakoľko sú však tieto akcie efektívne, t.j. nakoľko dobre je táto informácia

použitá, nevieme pri našom prístupe zachytiť. Keby bol pre niekoho takýto výklad kognície neprijateľný, nech si proste zamení toto slovo nejakým iným vhodnejším pojmom.




Fig. 1. Postavenie pomyselnéj užitočnej informácie v systéme

2 Použitie teórie informácie

Predstavme si robota, ktorý v uzavretej scéne s prekážkami vykonáva nejakú úlohu. Pre jednoduchosť uvažujme, že svojou činnosťou nemodifikuje scénu, ani žiadna iná dynamika sa v scéne neobjavuje. V zmysle Shannonovej teórie môžeme prostredie pokladať za zdroj informácie, robota za príjemcu tejto informácie a priebeh interakcie robota s prostredím za prenos informácie z prostredia do robota (Fig. 2).




Fig. 2. Kognícia ako informačný prenos

Čo to znamená, že sa na prostredie robota dívame ako na informačný zdroj? Pre jednoduchosť predpokladajme, že toto prostredie môže potenciálne nadobúdať jednu z N možností. Robot je vystavený jednej z týchto možností, ale nevie, ktorá to konkrétne je. Môže mať v princípe od začiatku zabudované určité informácie, ktoré dokážu niektoré možnosti od začiatku vylúčiť. Ako robot získava nové informácie z prostredia, môže ich použiť k tomu, aby zmenšil počet možností s ktorými môže mať dočinenia.

¹ Vid napr. http://www.eucognition.org/wiki/index.php?title=Definitions_of_Cognition

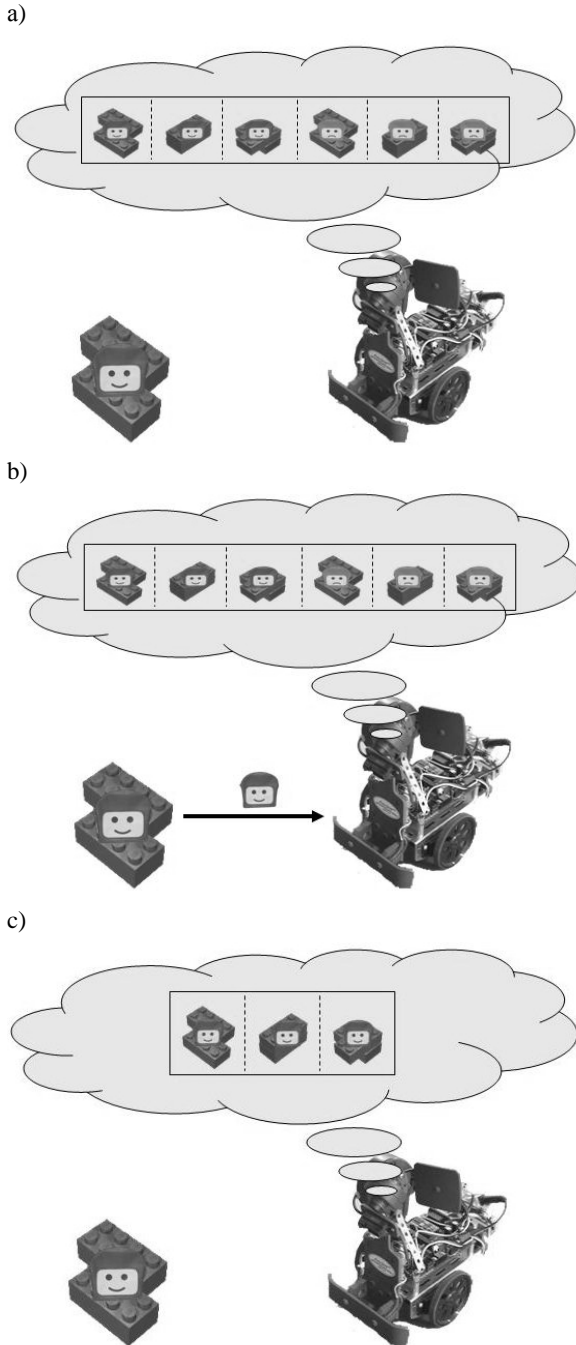


Fig. 3. Redukcia počtu možných stavov prostredia
 a) stav pred prenosom informácie
 b) prenos informácie
 c) stav po prenose informácie


Miera nakoľko je schopný tieto možnosti redukovať potom vyjadruje, nakoľko je schopný toto prostredie poznať. Môžeme sa na to dívať tak, že úlohou robota je uhádnuť akému prostrediu je vystavený. Ak túto úlohu zvláda, jeho predstava o prostredí je s časom stále menej a menej neurčitá. (Pre jednoduchosť pritom predpokladáme, že robot zhromažďuje o prostredí len korektné informácie.) (Fig. 3)

Akú mieru zvolit' na vyjadrenie miery neurčitosti (označme H) prostredia v predstavách robota? Stačil by na to v princípe samotný počet možností. O niečo šikovnejšie je však zvolit' logaritmus tohto počtu, lebo nám to umožňuje štruktúrovať stav prostredia ako usporiadanú n -tícu rôznych aspektov. Pokiaľ má stav sveta dve zložky, pričom prvá môže nadobúdať N možností a druhá M možností, tak celkový počet možností je $M \cdot N$. Keď robot odhalí najprv jednu zložku a potom druhú, malo by to byť to isté ako keď odhalí obe naraz. Toho plynie $H(M \cdot N) = H(M) + H(N)$ a z toho $H(N) = \log N$. Vhodnou mierou je teda práve Shannonova entropia informácie. (Fig. 3 demonštruje aj príklad jej použitia: svet má dve zložky: kocky - nadobúdajúce tri stavy - a tvár - nadobúdajúcu dva stavy. Dokopy teda môže nadobúdať 6 stavov. Odhalením stavu tváre, t.j. prenesením jedného (užitočného) bitu, sa počet možných stavov redukuje na polovicu, t.j. na 3. Ak informáciu počítame na bity, tak daný logaritmus musí byť dvojkový, t.j. $\log_2 6 - 1 = \log_2 3$.


3 Klasifikácia kognitívnych systémov

Na základe priebehu informačnej entropie v závislosti od času po ktorý je systém v prostredí aktívny, môžeme potom klasifikovať niekoľko typov systémov. My sa prikláňame k týmto piatim, ale uvedomujeme si, že túto klasifikáciu je možné poľahky rozšíriť i redukovať:


Typ I. entropia je konštantná. Príkladom môže byť robot s natvrdo zabudovanými reakciami na podnety.




Typ II. Entropia klesá ku hranici, ktorá je zabudovaná v štruktúre systému. Príkladom je robot, ktorý má zabudovanú schopnosť nakalibrovvať určitú sadu konštant. Napríklad robot rozpoznávajúci loptičku si postupne zoptimalizuje úroveň prahovania vyhraneneho obrazu podľa úrovne osvetlenia v scéne.




Typ III. Entropia klesá k limitu, ktorý je daný aplikačnou oblasťou. Príkladom je robot, ktorý disponuje vysoko flexibilnou štruktúrou, ktorej tvar je však podmienený zabudovanou spätnou väzbou. Robotovi je fixne dané čo mu dáva pozitívnu a čo negatívnu spätnú väzbu. Napríklad robot sa naučí dokonale rozpoznávať guľičky, ale nič iného.



Typ IV. Entropia klesá k limitu ktorý je daný senzormi a aktuátormi robota. Tu už ide o plne univerzálny poznávací systém.



Typ V. Entropia klesá pod limit daný senzormi. Takýto robot by si vedel zostrojiť napr. mikroskop umožňujúci mu pozorovať v scéne dovtedy nepozorovateľné, rovnako ako vrták, ktorým sa prevrta von zo scény a dostane sa do sveta, ktorý mu predtým nebol vôbec prístupný.



Vo všeobecnosti možno potom v zúženom zmysle „kogníciu“ definovať ako *schopnosť znižovať entropiu informácie, ktorou systém o prostredí disponuje*.

4 Odstraňovanie zjednodušeni

V predchádzajúcom výklade sme urobili rad zjednodušení a teraz sa pozrieme s ktorými z nich sa vieme popasovať.

- *fantomické informácie*. Dosiaľ sme predpokladali, že robot má o prostredí korektnú predstavu. Môže sa však stať, že vo svojej predstave počet možností zúži tak, že vylúči tú možnosť, ktorá práve nastáva. Tým pádom entropia môže klesať, ale v skutočnosti v tom nie je nič kognitívne. Toto je vážny problém, ktorý nevieme riešiť inak, než niečo také zakázať alebo povoliť len v rámci ponechania stavov, ktoré majú so skutočným stavom blízku spoločnú abstrakciu.
- *dynamické prostredie*. Dosiaľ sme predpokladali, že prostredie je nemenné. V skutočnosti v ňom môžu prebiehať samovoľné deje, periodické i neperiodické ako aj robot môže svojimi akciami toto prostredie meniť. Pokiaľ robot pri zmene prostredia upraví svoju predstavu o ňom tak, že je korektná, prejaví sa to len tým, že entropia niekedy aj stúpne. V istých prípadoch pomôže taktiež uvažovať miesto stavu množiny alebo postupnosti stavov.
- *rozdielna pravdepodobnosť jednotlivých možností*. Na tento problém nám dáva riešenie samotná Shannonova teória. Ak máme N stavov s pravdepodobnosťami p_1, p_2, \dots, p_N potom šikovný vzťah pre mieru neurčitosti predstavy o skutočnom stave je
$$\sum_{i=1}^N p_i \cdot \log(1/p_i).$$
- *šum*. Dáta, ktoré robot reálne získava senzormi sú zašumené. Šum neuvažujeme, preto je náš prístup aplikovateľnejší v počítačových simuláciách.

5 Príklad

Uvažujme robota, ktorý zisťuje v uzavretej scéne počet pingpongových loptičiek. (Nejde tu o reálne vykonaný experiment, ale podobné hardwarové prevedenie možno nájsť napr. v [4].) Požadujeme pritom korektnosť v tom zmysle, aby robot nikdy neurčil viac loptičiek než sa v scéne skutočne nachádza, môže však povedať o čosi menej.

Prostredie robota budeme aproximovať mriežkou $N \times M$ o veľkosti pingpongovej loptičky. Okrem loptičiek môžu byť v prostredí kocky príliš ťažké na to, aby s nimi robot pohol. To dáva s prázdnyim miestom dokopy $3 \times N \times M$ stavov. Na niektorých miestach je v scéne úplná tma a robot tam žiadne loptičky nedokáže vidieť. Na iných miestach sa loptičky dotýkajú kociek s rovnakou farbou, čo veľmi zťažuje ich rozpoznanie. Niektoré guľičky sú pre robota nedostupné, lebo sú zastavané kockami.

Robot vopred nevie, aké svetelné podmienky v scéne panujú, čo môžeme reprezentovať tak, že nevie ktorý z P vhodných prahov treba použiť pri vyhranení obrazu.

Predpokladajme ďalej, že robot nemá zabudované fyzikálne poznatky ako je možnosť tlačenia loptičiek. Aj takýto poznatok má zmysel v stave sveta reprezentovať a to napríklad binárne: má ho – nemá ho.

Stav sveta preto zvolíme tak, svet pre robota predstavuje jednu z $3 \times M \times N \times P \times 2$ možností a počiatočná entropia je teda $\log_2(3 \times M \times N \times P \times 2)$

Robot je vybavený pohybom, kamerou a navigačným zariadením, ktoré mu hovorí, kde sa v scéne nachádza.

Ak teraz urobíme riadiaci systém robota tak, že bude prechádzať scénou približne tak ako keď sa orie (nakolko mu to prekážky dovoľia) a to dostatočne opatrne tak, aby ničím nepohol a použije pritom len jeden priemerný prah, podarí sa mu niektoré guľičky identifikovať, iné nie. Entropia teda klesne na $\log_2(3 \times (M \times N - X) \times P \times 2)$, kde X je počet miest, kde sa robotovi podarilo identifikovať, čo sa tam nachádza. Pokiaľ by na Y miestach z týchto X miest vylúčil len jednu z možností, ale nemá istotu, ktorá z dvoch ďalších tam nastáva, bude to len $\log_2(3 \times (M \times N - X) \times 2 \times Y \times P \times 2)$. (viď R1 na Fig. 4)

Keď teraz riešenie prerobíme tak, že sa robot pohybuje náhodným smerom tak, aby sa raz za čas dostal do každého miesta scény, jeho šanca na identifikáciu loptičiek sa zvýši vďaka tomu, že sa na konkrétnu loptičku pozrie z viacerých pohľadov. Vzťah pre entropiu ostane rovnaký, ale X sa zvýši a Y zníži. (viď R2 na Fig. 4)

Keď ďalej začne robot hľadať optimálny prah pre spracovanie obrazu, môže k tomu pristúpiť dvomi spôsobmi. Môže všade vyskúšať všetky prahy, čo dá lepší výsledok, ale bude to P-krát pomalšie (ten istý vzťah pre entropiu s lepším X a Y, ale iný priebeh v čase) (viď R3 na Fig. 4). Môže si však zistené svetelné podmienky pamätať, čo ho síce v úvodnej fáze zdrží, ale keď už bude vedieť aké svetelné podmienky kde panujú, bude dosahovať lepšie výsledky a rovnako rýchlo. Pritom entropia sa zníži výrazne na $\log_2(3 \times (M \times N - X) \times 2 \times Y \times 2)$. (viď R4 na Fig. 4)

Robot ktorý by sa navyše snažil tlačíť predmety v scéne, pričom by reflektoval vo svojej predstave o scéne následky presunu predmetov, by mohol zistiť, že tlačением sa pohne práve guľička. Mohol by preto zájsť do tmy a vytlačiť odtiaľ všetko čo sa dá na svetlo a tam sa na to pozrieť. Samotným poznaním tohto pravidla by odbúral entropiu na $\log_2(3 \times (M \times N - X) \times 2 \times Y)$ a následne by zlepšil X a Y. Bolo to ale za cenu, že sa mu sem-tam niektorá guľička pri tlačení zakotúľa, čo prechodne zníži X, resp. zvýši Y. (viď R5 na Fig. 4)

Pozoruhodné je všimnúť si na tomto príklade, že skúmaná entropia nemá žiaden priamy vzťah k úlohe, ktorú robot vykonáva. Vyjadruje však nevyhnutné predpoklady ku realizácii úlohy a je schopná kvalitu týchto predpokladov vzájomne porovnávať.




Fig. 4. Ilustrácia priebehu entropie v závislosti od času pre rôzne riešenia z uvádzaného príkladu

6 Vzťah k biologickej evolúcii

Hlavná úvaha, na ktorej je postavený celý vyššie uvedený prístup je dobre známa v kognitívnej biológii [3]. Na rozdiel od robotov, ktoré konštruujeme, však pre biologické systémy nie je možné priebeh entropie vyčíslieť (z dôvodu nedostatku znalostí o vnútornej štruktúre systému). Robotika a to predovšetkým evolučná robotika [1] je teda neoceniteľným prostriedkom na isté poodhalenie analogických princípov biologickej evolúcie. Pri takýchto simuláciách musíme sledovať nielen pokles entropie v konkrétnom prostredí u konkrétneho jedinca, ale jednak štartovaciu hodnotu entropie (danú vrodennými informáciami o prostredí), jednak hodnotu na ktorú v priemere pri vložení do jednotlivých možností prostredia entropia klesá. Rozdiel týchto dvoch hodnôt nám potom zviditeľňuje plasticitu jedinca. Takisto musíme brať v úvahu, že v priebehu evolúcie sa môže meniť samotné prostredie. Napríklad parazit bude mať zrejme menšiu schopnosť znižovať entropiu, ale bude pravdepodobne vyvážená zjednodušením prostredia. Entropia bude teda stále klesať, s výnimkou obdobia prudkej zmeny prostredia (Fig. 5). Podobne pokiaľ nejakého jedinca premiestnime z prostredia v ktorom je entropia relatívne nízka do iného prostredia, entropia sa tým pádom enormne zvýši – jeho predstava síce obsahuje stále rovnakú informáciu, ale táto už nič nevytvorí o prostredí v ktorom sa nachádza. Preto keď človeka premiestnia do prostredia obývaného žralokom, stráca akúkoľvek výhodu zo svojich lepších vedomostí. Pokiaľ má však dostatok času, dokáže sa vďaka svojej plasticite

aj v tomto prostredí proti žralokovi presadiť, nakoľko žralok so svojou nízkou plasticitou s ním nemôže dlhodobo súťažiť.

[7] Šefránek J.: *Kognícia bez mentálnych procesov*. In. *Kognitívna veda* (Beňušková, L. - Kvasnička, V. – Rybár, J. eds.), Kaligram 2002




Fig. 5. Ilustrácia priebehu vrodenej entropie H_0 a priemernej dosiahnutej entropie H v jednotlivých generáciách v priebehu evolúcie

7 Záver

V príspevku sme sa snažili aplikovať myšlienky Shannonovej teórie informácie a kognitívnej biológie v oblasti robotiky. Ukázali sme akým spôsobom sa dá niečo ako „kognícia“ (v užšom význame tohto slova) vyčíslit' pre konkrétny robotický systém a navrhli sme ako by sa na základe toho dali tieto systémy klasifikovať. Za prínos považujeme, že hoci samotná myšlienka nie je originálna, uvádzame ju v detailnosti vhodnej pre reálne použitie – pre vybudovanie a aplikovanie niečoho ako „matematická teória kognície“.

Literatúra

- [1] Gažák, M.: *Evolučná robotika. Kognice a umělý život V*, SLU Opava, 2005
- [2] Horáková, J. - Kelemen, J.: *Kouzlo a síla interakce. Kognice a umělý život V*, SLU Opava, 2005
- [3] Kováč, L.: *Komentovaný úvod do kognitívnej biológie*. Kognice a umělý život IV, SLU Opava 2004
- [4] Lúčný, A.: *Od mezimodulových spojení k nepriamej komunikácii medzi agentami*. ZNALOSTI, VŠB Ostrava, 2007
- [5] Metta, G. – Vernon D. – Sandini, G.: *The RobotCub Approach to the Development of Cognition*. AISB Quarterly, The Newsletter of the Society for the Study of Artificial Intelligence and Simulation of Behaviour, No. 121, p. 4, 2005
- [6] Shannon, C. E.: *A Mathematical Theory of Communication*. Bell System Technical Journal, 27, pp. 379–423 & 623–656, July & October, 1948