

# Fúzia senzornej informácie a detekcia/diagnostika porúch v robotike

Anton Vitko  
Michal Šavel  
Ladislav Jurišica

V prvej časti sú opísané niektoré metódy zberu a fúzie senzornej informácie v robotike a neurónová sieť PCL sieť ako príklad nástroja extrakcie znakov. V druhej časti je stručný opis analýzy chybových stavov, ich rozpoznávanie a klasifikácie a neurónová sieť ART ako príklad nástroja zhlukovej analýzy a klasifikácie porúch.

## Úvod

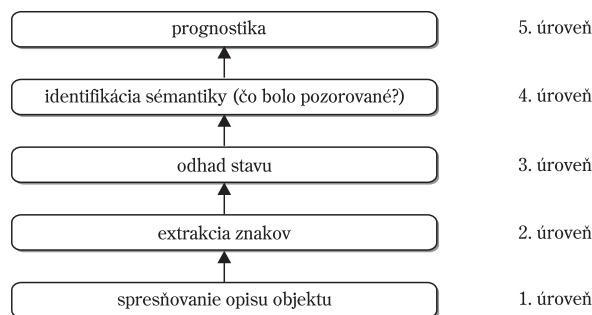
Inteligentný robotický agent, napr. robot pohybujúci sa a operujúci v neznámom prostredí bez asistencie človeka, má byť schopný efektívne rozpoznať a spracovať svoje vlastné poruchové stavy ako aj zmeny v prostredí a tak zabrániť vzniku hazardných situácií. Preto je vystrojený prinajmenej dvomi podsystémami – podsystémom vnímania a podsystémom rozhodovania. Úlohou prvého je pomocou vhodne vybraných druhov senzorov snímať svoj vlastný vnútorný stav a stav okolia a získané multimediálne signály predspracovať a integrovať do konzistentného opisu okamžitého stavu systému robot – prostredie. Druhý podsystém je zodpovedný za generovanie správnych rozhodnutí o ďalších aktivitách. Chovanie sa inteligentného robotického agenta je spravidla čiastočne alebo úplne autonómne, generované výlučne na základe získanej senzornej informácie. Aby to bolo možné, robot musí byť schopný učiť sa na základe vlastných skúseností. Predpokladom ku vnímaniu stavu je schopnosť extrahovať neúplnú multimediálnu informáciu zo zašumených signálov a integrovať ju do podoby umožňujúcej generovať jej sémantický obsah. Dôležitou podúlohou tohto problému je generovanie istých zhlukov signálov, (clusterov) ktoré sú si navzájom podobné na základe zvolenej miery podobnosti. Zhluky signálov (resp ich centrá) potom reprezentujú prototypy normálnych či patologických situácií a správání. Ich rozpoznanie je prvým krokom k inteligencii robota pri riešení nových a často hazardných situácií. Jednou typickou skupinou takýchto situácií sú práve poruchové stavy, ktoré musia byť náležite diagnostikované a robot musí na ne adekvátne reagovať.

Bolo vinutých veľa metód fúzie senzornej informácie, ich opis však presahuje rámec príspevku. Myšlienka stojaca v pozadí všetkých, spočíva v synergickom využití redundancie a diverzity vzájomne sa prekrývajúcej informácie obsiahnutej v multimediálnych senzorných signáloch, s cieľom získať agregatívny pohľad, teda to, čo nie je obsiahnuté v žiadnom parciálnom signále. Fúzia senzornej informácie je súčasťou širšie ponímanej snahy o „doloženie informácie“, chápanej ako netriviálna extrakcia implicitnej, predtým neznámej a potenciálne užitočnej informácie z nekompletných údajov. Ide predovšetkým o extrakciu istých pravidielností a podobností skrytých v signáloch získaných zo senzorov [1].

## Metódy zberu a fúzie senzornej informácie.

Ako ukazuje obr. 1, fúzia informácie sa realizuje v niekoľkých úrovniach. Na najnižšej úrovni sa spravidla realizuje filtrácia signálov, včítane kontroly úrovni, výpočtu stredných hodnôt, modulácie, kvantovania a transformácie do spoločných časovo-priestorových merítok. Na druhej úrovni prebieha asociácia signálov nasledova-

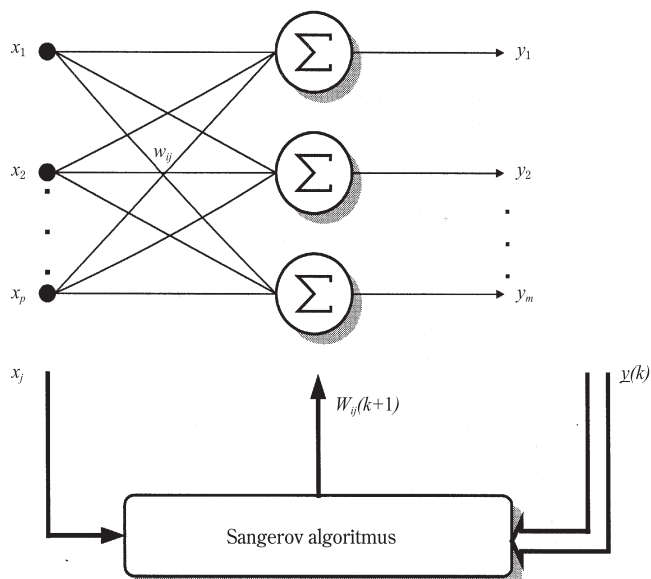
ná extrakciou (prí)znakov. Na báze použitej korelačnej metriky a/alebo miery podobnosti sa signály asociujú. Napr. v prípade vizuálnej informácie vznikajú 2D obrazy fúziou pixelov s nižšími hodnotami gradientu osvetlenia. (Prí)znak je vzor nachádzajúci sa v množine signálov, ktorý sa manifestuje koreláciou medzi niektorými zložkami viacerých signálov. Najjednoduchšou formou asociácie je definovanie nových veličín. Niektoré pôvodné veličiny sa pritom nahrádzajú novými, ktoré majú z hľadiska interpretácie väčší význam. (napr. pomer šum/signál), alebo sa počet údajov môže redukovať zmenou granularity .



Obr.1 Hierarchia zberu a fúzie senzornej informácie

Zvlášť významný prostriedok redefinície veličín je aplikácia metódy hlavných komponentov (PCA – Principal Component Analysis). Metóda PCA umožňuje optimálne redukovať rozmernosť priestoru vstupného údajového priestoru pri súčasnej extrakcii maximálneho množstva informácie. Metóda je založená na známom výsledku teórie informácie, totiž že najviac informácie poskytuje signál s najväčšou entropiou. Snahou je vyjadriť informáciu obsiahnutú vo veľkom počte „informačne chudobných“ snímaných veličín menším počtom nových veličín pri zachovaní maximálneho množstva pôvodnej informácie. Informácie poskytované jednotlivými senzormi nie sú nezávislé. Je možné to isté množstvo informácie vyjadriť menším počtom „informačne bohatších“ a vzájomne nezávislých veličín, alebo tzv. hlavných komponentov. Prvý z hlavných komponentov sa definuje ako lineárna kombinácia premenných s najväčším rozptylom. Druhý hlavný komponent je daný lineárnou kombináciou ďalších premenných s najväčším rozptylom atď. Zo štatistického prístupu k hľadaniu hlavných komponentov vyplýva, že smery najväčších rozptylov sú dané vlastnými vektormi vstupnej korelačnej matice, ktoré zodpovedajú najväčším vlastným hodnotám. Najviac informácie obsahuje prvý hlavný komponent, (atribút) teda ten ktorý je generovaný z informácie o vlastnom vektore ktorý zodpovedá najväčšej vlastnej hodnote. Ak je možné takto vzniknutým hlavným komponentom priradiť sémantický význam, môžu byť použité v ďalšom mechanizme pre extrakciu vedomostí. Klasická štatistická aplikácia metódy hlavných komponentov teda vyžaduje výpočet vstupnej korelačnej matice ako aj jej vlastných hodnôt a vlastných vektorov. Metóda sa však dá elegantne implementovať on-line, prostredníctvom jednovrstvovej doprednej neurónovej siete znázornenej na obr. 2, ktorá adaptuje svoje váhy tak ako prichádzajú vektory senzorných signálov. Sieť obsahuje len lineárne neuróny, ktorých počet je menší ako počet





Obr.2 PCA neurónová sieť

vstupov (redukcia dimenzionality). Adaptáciu váh zabezpečuje zo všeobecnej Hebbov algoritmus (Sangerov algoritmus) [3]:

$$\Delta W_{ji}(n) = \eta y_j(n)(x'_i(n) - W_{ji}y_j(n))$$

$$i = 1, 2, \dots, p \quad j = 1, 2, \dots, m$$

kde

$$x'_i(n) = x_i(n) - \sum_{k=1}^{j-1} W_{ki}(n)y_k(n)$$

Koeficient  $\eta$  je rýchlosť učenia, ktorý rozhoduje aj o stabilite procesu [8]. Sieť potom pracuje ako asociátor pôvodných sensorových signálov  $\underline{x}$  a ich atribútov  $\underline{y}$ .

Tretia úroveň je vyhradená pre odhad stavu robota a prostredia (napr. odhad vzdialenosti a smeru najbližšej prekážky, odhad trajektórie pohybujúcej sa prekážky, či postupnosti vnútorných stavov robota). Možno použiť Kalmanov (rozšírený) filter, ktorý odhaduje stav na základe sekvencie sensorových pozorovaní. Samozrejme, pohybové rovnice a kovariancie šumov objektu ako aj meracích šumov musia byť známe.

Na štvrtej úrovni sa realizujú sofistikované procedúry identifikácie pojmov, t.j. hľadá sa odpoveď na to „čo bolo pozorované“ resp. „čo to značí, že to a to bolo pozorované“. Táto úroveň je aplikačnou doménou nástrojov ktoré sú schopné priamo spracovať neistoty. Ide hlavne o aplikácie teórie fuzzy množín a fuzzy logiky, teórie pravdepodobnosti a Dempsterovej-Shaferovej teórie dôkazu (evidence theory). Teória fuzzy množín umožňuje návrh fuzzy expertných systémov pre inferenciu relácií a poznatkov na základe aplikácie fuzzy produkčných pravidiel na snímané signály. Ak sa ako inferenčný nástroj použijú metódy teórie pravdepodobnosti, dominantnú úlohu tu zohráva Bayesov zákon, ako inferenčný mechanizmus pre znižovanie neistoty vo svetle nových pozorovaní. Zovšeobecnením Bayesovskej teórie je práve Dempster-Shaferova teória dôkazu. Tu úroveň dôveryhodnosti daného výroku nič neimplikuje o úrovni dôveryhodnosti jeho doplnku. Inými slovami, poskytuje nástroj pre vyjadrenie nevedomosti (ignorancie), čo nie je nič iné ako efektívny nástroj pre manipuláciu s chýbajúcimi údajmi. Podobne ako Bayesova teória, aj Dempsterova-Shaferova teória poskytuje nástroj pre modifikáciu apriórneho poznatku vo svetle nových pozorovaní. Z hľadiska detekcie a rozpoznávania chýb poskytuje Dempsterova-Shaferova teória efektívny prostriedok umožňujúci formulovať isté tvrdenie (resp. dôkaz) na základe kombinácie tvrdení získaných ako výstupy viacerých primárnych detektorov (a klasifikátorov) vzniknutých chýb [4], [5].

Na najvyššej úrovni môže byť implementovaný prognostický systém predpovedajúci spoľahlivosť komponentov vzhľadom na rôzne

príčiny zlyhania spoľahlivosti alebo výkonnosti, napr. únavy materiálu, deštrukcií komponentov, komunikačných chýb a pod.

Medzi kľúčové požiadavky kladené na systém detekcie a diagnostiky porúch patrí predovšetkým:

1. On-line operabilita,
  2. Včasná detekcia, diagnostika a indikácia kritických porúch,
  3. Schopnosť reprezentovať relatívne komplexné relácie medzi vzniknutými (hroziacimi) poruchami a sensorovými signálmi.
- Jedným z najdôležitejších aspektov je tiež vyhodnotenie stupňa nebezpečenstva vyplývajúceho z porúch rôznych komponentov. Systém detekcie a diagnostiky má klásť vyššiu prioritu chybám s najväčším vplyvom na operabilitu robota.

Požiadavky uvedené v bode 3 možno rozšíriť aj na identifikáciu relácie medzi poruchou a jej prejavom. Systém má identifikovať všetky abnormality v normálnom chode a z nich dedukovať možné poruchy komponentov. Každá porucha či degradácia činnosti komponentov generuje istý pozorovateľný efekt na kvalitu operácií. Navyše, relácia medzi poruchou a jej symptómom sa mení s postupom poruchy od jej počiatočných štádií do neskorších štádií. Niekedy môžu byť užitočné aj sekundárne symptómy (rýchlosť postupu poruchy, pravdepodobnosť poruchy, ...).

## Detekcia porúch

Každú poruchu (fault) treba chápať ako príčinu istej disfunkčnosti (failure), t. j., neschopnosti vykonať službu, ktorú systém normálne vykonáva [6]. Môže to byť strata optimálneho výkonu, krútiaceho momentu, vynechanie signálu, nedoručenie správy a pod. Bežnými príčinami disfunkčnosti systému sú buď poruchy prvkov systému alebo poruchy senzorov resp. prenosových ciest. V oboch prípadoch sa manifestujú ako narušenia integrity vstupných údajov a mali by byť detekované už algoritmi zabezpečujúcimi fúziu údajov, alebo algoritmi potvrdzujúcimi akceptovateľnosť údajov dodávaných senzormi na základe snímania iných, s nimi súvisiacich veličín. Disfunkčnosti „vyššieho rádu“ (cognitive failures) vznikajú v inferenčných procesoch vedomostných podsystémoch inteligentných systémov robotov a ide zvyčajne o neschopnosť riešiť daný problém, napr. neschopnosť navigátora nájsť voľnú cestu medzi prekážkami. Môžu byť spôsobené bežnými poruchami, ale aj neočakávanými zmenami prostredia, ktoré nie sú sensorovým podsystémom zaznamenané, neúplnosťou či nekonzistentnosťou množiny pravidiel fuzzy navigátora a pod. Príčiny takýchto disfunkčnosti možno len ťažko automaticky detekovať. Medzi **súčasné prístupy** k diagnostike porúch v robotike patria predovšetkým nasledujúce prístupy a ich prípadné kombinácie:

**1. Modelovo založené diagnostiky.** Princíp spočíva v on-line identifikácii dynamického modelu a kontinuálnom porovnaní jeho parametrov s parametrami nominálneho modelu. Nenulový rozdiel potom detekuje poruchu a diagnostický algoritmus ju ďalej špecifikuje. Hlavným nedostatkom takéhoto prístupu je skutočnosť, že neexistuje jedno-jednoznačná korešpondencia medzi modelovými a fyzikálnymi parametrami. Alternatívnym prístupom, ktorý eliminuje uvedený nedostatok je porovnanie normálnych a poruchových rozložení pólov a núl (celých koreňových hodnôf), ale je obmedzený na lineárne systémy.

**2. Diagnostiky založené na využití expertných systémov.** Vedomosti experta sú vyjadrené vo forme if-then pravidiel, v sémantických sieťach alebo symptomatických stromoch. Hoci detekcia a diagnostika porúch založená na báze expertných systémov funguje v bežných prevádzkach, v moderných rozsiahlych a zložitých priemyselných procesoch nepostačuje. Problém je v tom, že vedomosti súvisiace s niektorými poruchami buď nie sú k dispozícii, alebo sú nedostatočné. V tomto smere poskytujú nové možnosti neurónové siete, fuzzy logika.

**3. Diagnostiky založené na využití fuzzy-neuro prístupoch.** Tieto predstavujú v súčasnosti najpopulárnejšie prostriedky vzhľa-

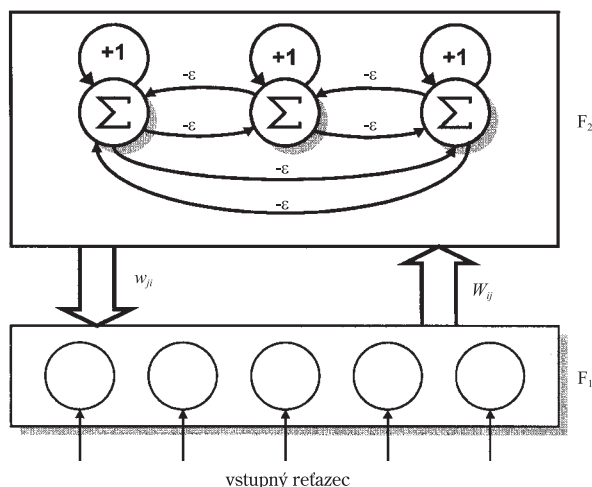
dom na ich schopnosť spracovať nepresne a neúplne definované hodnoty a schopnosť učenia sa zo skúsenosti.

Detektor porúch pracuje nad množinou očakávaných signálov, definovanou napr. limitnými hodnotami výstupov senzorov, typom, dĺžkou a štruktúrou číslicových a logických reťazcov, časovými konštantami monitorovaného procesu, pomerom signál-šum a pod. Signály nachádzajúce sa mimo tejto množiny (včítane ich absencie) sú detekované ako poruchy a musia byť ďalej diagnostikované. Z predchádzajúceho vyplýva, že v rámci diagnostiky ide o porovnávanie chybových signálov na základe zvolenej metriky a ich asociácie s možnými prototypmi porúch. V prípade, že sa nenájde žiadny známy prototyp vzniknutej poruchy vytvorí sa nový, teda detektor/identifikátor poruchy musí pružne reagovať aj na nepoznané poruchy. Práve opísaný proces sa realizuje v inteligentnom identifikátore/klasifikátore porúch na báze neurónovej siete ART (adaptive resonance theory).

### Adaptive Resonance Theory (ART) neurónová sieť ako klasifikátor porúch

Treba povedať, že prakticky každá dopredná neurónová sieť, ak bola naučená na dostatočne veľkej trénovanej množine môže byť použitá na klasifikáciu budúcich, predtým nepredložených vzorov, pokiaľ sú dostatočne podobné tým vzorom na ktorých bola sieť trénovaná. Žiaľ, v praxi nemáme vždy k dispozícii takúto trénovanú množinu, ba dokonca ani nevieme povedať aký vzor (poruchy) by do nej mal patriť. Preto boli snahy vyvinúť sieť ktorá by bola plastická aj dostatočne stabilná pri úlohe kategorizácie a klasifikácie. ART neurónová sieť bola pôvodne vyvinutá pre účely zhlukovej analýzy binárnych reťazcov ako odpoveď na problém tzv. stability a plasticity neurónových klasifikátorov postavených na báze dopredných neurónových sietí [7]. Ide o to že sieť má byť dostatočne plastická v odpovedi na významné rozdiely vo vstupných signáloch, ale pritom nemá reagovať na malé rozdiely. Má teda byť dostatočne robustná, čo je pri detekcii porúch veľmi dôležité. Jednou z predností siete ART je aj možnosť jednoducho nastaviť požadovanú mieru podobnosti analyzovaných vstupov. Ako ukazuje obr. 3, sieť v princípe pozostáva z dvoch vrstiev neurónov.

Medzi neurónmi vo vrstve  $F_2$  sú vytvorené postranné záporné väzby ( $-\epsilon$ ) a vlastné kladné spätné väzby ( $+1$ ). Každý neurón vo vrstve  $F_1$  je prepojený spojmi s váhami  $w_{ij}$  s každým neurónom vo vrstve  $F_2$  a naopak, každý neurón vo vrstve  $F_2$  je prepojený s každým neurónom spojmi s váhami  $w_{ji}$ . Vstupná vrstva obsahuje toľko neurónov, koľko rádoov má vstupný reťazec, kým vrstva  $F_2$  obsahuje toľko neurónov, do koľkých tried (zhlukov-clusterov) sa vstupné vzory majú kategorizovať, teda koľko kategórií porúch sa predpokladá. Siete typu ART sa realizujú v niekoľkých verziách. Je to predovšetkým sieť ART-1 s binárnymi vstupmi, ďalej ART-2, Fuzzy ART, Fuzzy ARTMAP, ktoré spracúvajú analógové vstupy. Vďaka



Obr.3 Ideová schéma ART neurónovej siete

excitačným vlastným a inhibičným postranným väzbám, po predložení vstupu začne vo vrstve  $F_2$  prebiehať súťažné učenie (competitive learning), ktorého výsledkom je jediný víťazný neurón (neurón s nenulovým výstupom), zatiaľ čo výstupy všetkých ostatných neurónov vrstvy  $F_2$  sú nulové. Víťazom bude neurón s najväčším súčtom vstupných signálov. Nech je to  $j$ -ty neurón. Jeho výstupný signál sa cez váhy  $w_{ji}$  propaguje naspäť do vrstvy  $F_1$ . Prijateľnosť  $j$ -teho neurónu ako reprezentanta triedy do ktorej by mal predložený vstup patriť, sa kontroluje podmienkou

$$\left| \frac{(I \wedge w_{ji})}{|I|} \right| > \rho \quad (1)$$

kde  $I$  je vstupný reťazec, znak  $\wedge$  predstavuje v prípade ART-1 logický súčin, v prípade Fuzzy ART operátor fuzzy-min, a  $|\cdot|$  je počet zložiek vektorov. Číslo  $\rho$  je tzv. bdelostný parameter. Čím je vyšší, tým vyššia podobnosť medzi vstupom  $I$  a  $w_{ji}$ , sa vyžaduje. Ak je podmienka (1) splnená, (nastala rezonancia medzi vstupom a vektorom  $w_{ji}$ ) váhy  $w_{ji}$  sa adaptujú napr. podľa predpisu

$$w_{ji} \leftarrow (I \wedge w_{ji}) \quad (2)$$

a rovnako až na skalárny faktor, sa adaptujú aj váhy  $w_{ij}$ . Ak podmienka (1) nie je splnená, teda podobnosť nie je dostatočná,  $j$ -ty neurón vo vrstve  $F_2$  sa diskvalifikuje ako víťaz, vyberie sa iný ktorý nebol diskvalifikovaný a proces sa opakuje. Takýmto postupom sa každému clusteru podobných vstupov (reťazcov reprezentujúcich konkrétne chyby) priradí jeden neurón vo vrstve  $F_2$  sa stane reprezentantom tohto clusteru. Podrobnosti o štruktúre a riadení operácií v sieťach ART ako aj algoritmoch učenia sú v [7].

### Literatúra

- [1] W. G. FENTON: Fault Diagnosis of Electronic Systems Using Intelligent Techniques. IEEE Trans. Syst. Man. Cyb. Part C, August 2001, No. 3, 269-281
- [2] S.S. ANAND et al.: Designing a Kernel for Data mining, IEEE Expert, March-April, 1997.
- [3] YONG-ZAI LU: Industrial Intelligent Control. John Wiley&Sons, Ltd.,1996
- [4] M. DHAR et al.: Diagnostic and Data Fusion of Robotic Sensors. <http://www.mworld.rydia.net/robotic>
- [5] C. R. PARIKH et al.: Application of Dempster-Shafer Theory in Condition Monitoring. Applications: A Case Study., Pattern Recognition Letters, 22, (2001). 777-785
- [6] T. S. PERRAJU: Specifying Fault Tolerance in Mission Critical Intelligent Systems. Knowledge Based Systems, 14, (2001), 385-396
- [7] G. A. CARPENTER, S. GROSSBERG: Fuzzy ART : Fast Stable Learning and Categorization of Analog Patterns by an Adaptive Resonance System., Neural Networks, 4 (1991), 759-771
- [8] T. D. SANGER: Optimal Unsupervised Learning in a Single-layer Linear Feedforward Neural Networks. Neural Networks, 12, (1989), 459-473

doc. Ing. Anton Vitko, CSc.  
Ing. Michal Šavel

Katedra automatizácie a merania, SJF STU, Bratislava

prof. Ing. Ladislav Jurišica, PhD.

Katedra automatizácie a regulácie, FEI STU, Bratislava