About the Generalized Reasoning Methods and their Use in Semiotic Systems

Prof.dr. Mihaela MUNTEAN, Conf.dr. Cornelia MUNTEAN
West University of Timişoara

In computational semiotics the problem is to emulate a semiosis cycle within a digital computer. This needs the construction of intelligent systems, able to perform intelligent behavior, such as sensorial perception, world modeling, value judgement and behavior generation. These intelligent systems could be generally implemented through object networks and the basic functions mentioned above could be obtained by generalization of some elementary knowledge operators. Based on the three main reasoning methods, deduction, induction and abduction, well known in the philosophy of science and used in AI systems, there were three knew knowledge operators defined: knowledge extraction, knowledge generation and knowledge generation, operators that could be viewed as generalized interpretations of the standard reasoning procedures. This paper presents these new concepts and their connection, the current understanding of generalized deduction, induction and abduction and also how these operators could serve as the building blocks of universal intelligent systems.
Keywords: *Semiotic System, Knowledge Units, Deduction, Induction, Abduction*

1 Semiotica şi sistemele inteligente

1.1. Introducere

În studiul sintactic, semantic şi pragmatic al simbolurilor ca parte a vieţii sociale [1], ştiinţă numită semiotică, se încearcă o emulare a ciclului de semioză (transfer şi transformare a simbolurilor) cu ajutorul calculatorului digital. Acest lucru necesită construirea de sisteme inteligente, capabile de comportamente inteligente, ca percepţia senzorială, modelarea mediului, analiza valorilor şi generarea comportamentului. Modelarea matematică a unui astfel de sistem semiotic a fost în ultimul timp subiectul mai multor cercetări cu privire la relaţia dintre semiotică şi sistemele inteligente.

Mai mulţi cercetători şi-au propus să descopere unităţile elementare sau minime de inteligenţă, adică un set minim de operatori care să facă posibilă construirea unui comportament inteligent în cadrul unui sistem inteligent. Astfel merită menţionaţi Albus J. şi lucrarea sa [2] şi Meystel A. cu algoritmul său GFACS, prezentat în [3]. Ulterior, Ricardo R. Gudwin (în [4] şi [5]) a propus un set alternativ de operatori, numiţi extragerea cunoaşterii, generarea cunoaşterii şi selecţia cunoaşterii, care ar putea fi percepuţi ca o generalizare a strategiilor de raţionament deductiv, inductiv şi respectiv a abducţiei.

În continuare lucrarea de faţă va prezenta aceste concepte noi, modul de înţelegere la ora actuală a deducţiei, inducţiei şi abducţiei generalizate şi felul în care operatorii propuşi de Gudwin pot fi utilizaţi ca blocuri elementare pentru construirea sistemelor inteligente universale.

1.2. Unităţi de cunoaştere

Piesele elementare de cunoaştere, numite şi unităţi de cunoaştere, reprezintă, am putea spune, „un fir” de informaţie codat într-o structură.

Pentru a prezenta mai clar fundalul filozofic ce stă la baza unei astfel de definiţii pentru unităţile de cunoaştere, vom porni de la considerentul că există o ***lume reală***, compusă dintr-un set de fenomene dinamice continue care decurg în paralel. Desigur noi nu putem cunoaşte ***tot*** din această lume reală, ci doar ceea ce putem percepe prin simţurile noastre, adică aşa-numitul ***mediu sensibil*** al nostru sau ***Umwelt***, cum este numit acest mediu în literatura de specialitate [5]. Acesta nu reprezintă însă realitatea, ci doar cea mai bună înţelegere a noastră cu privire la realitate. Astfel, simţurile noastre sunt sursa unei informaţii continue dar parţiale despre fenomenele ce au loc în lumea reală. Din această sursă de informații se extrag aşa-numitele ***singularități***, adică acele grupuri de informații care pot fi cuprinse într-un singur concept (figura 1).

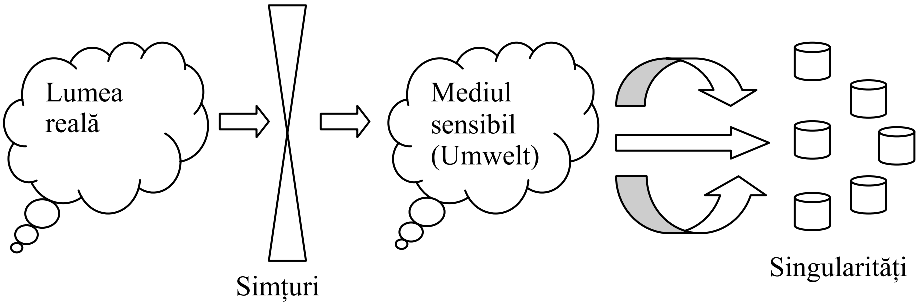

Fig.1. Extragerea singularităților

După ce aceste singularități sunt identificate în mediul sensibil, ele trebuiesc codificate pentru a deveni unități de cunoaştere, conform definiției enunțate mai sus. Această codificare necesită un **spațiu de reprezentare** şi o **structură de reprezentare** plasată în acel spațiu. Această structură poate fi abstractizată ca fiind o structură matematică de tipul numere (a), liste (b), arbori (c) şi grafuri (d) – a se vedea figura 2.

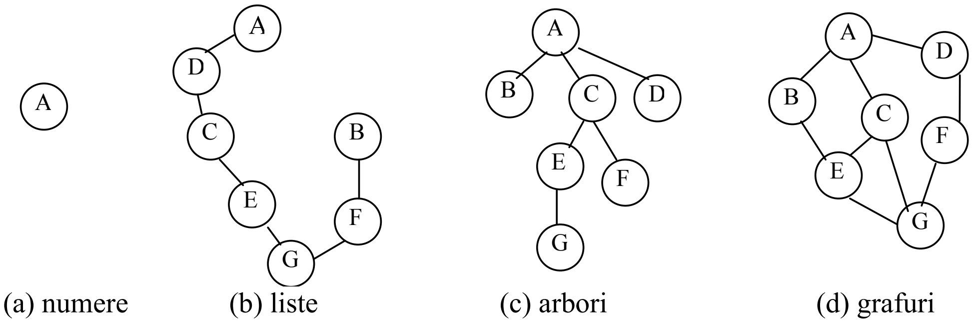

Fig.2. Structuri matematice

În continuare, ne putem închipui că spațiul de reprezentare conține un set de valori care ocupă fiecare un anumit loc în spațiul tridimensional. Pentru a forma unitățile de cunoaştere trebuie focalizată atenția asupra unui anumit grup de valori, adică selectată o anumită regiune închisă a spațiului de reprezentare. În urma interpretării, singularitățile respective devin structuri, ca cele din figura 3.

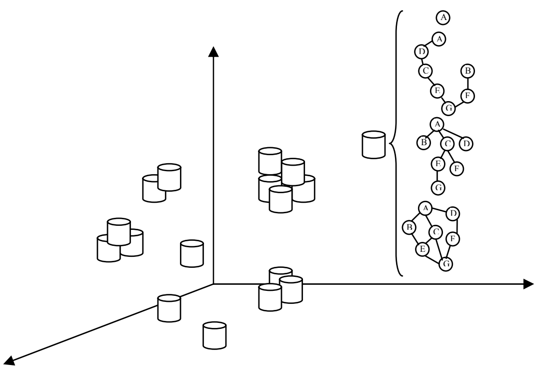

Fig.3. Spațiul de reprezentare conținând structuri matematice

Astfel, unităţile de cunoaştere se formează datorită acestor mecanisme de extragere a singularităţilor. Unităţi de cunoaştere mai complexe însă se formează aplicând operatorii de procesare a cunoştinţelor despre care vom vorbi în continuare, şi anume: extragerea, generarea şi selecţia cunoştinţelor.

2. Operatorii elementari de cunoaştere şi generalizarea lor

2.1. Generalizarea şi specializarea

Unităţile de cunoaştere pot fi comparate unele cu altele prin intermediul unui operator de relaţie de abstractizare ($\prec$). Astfel, dacă două unităţi de cunoaştere *a* şi *b* respectă relaţia $a \prec b$ spunem că *b* este o abstractizare sau o generalizare a lui *a* sau că *a* este o specializare a lui *b*. Aceste concepte sunt fundamentale pentru definiţiile care vor urma în ceea ce privşte extracţia, generarea şi selecţia cunoaşterii. Punctul cheie în înţelegerea relaţiei de abstractizare sunt cele două modalităţi de definire a unui set de valori: Modalitatea *extensivă* cere listarea explicită a tuturor elementelor setului şi poate fi aplicată doar pentru seturi finite de elemente, şi modalitatea *intensivă*, care reprezintă un set infinit de valori utilizând un set finit de parametri. Această a doua modalitate implică o codificare capabilă să convertească din reprezentarea intensivă elemente în reprezentarea extensivă.

De exemplu, definim intensiv setul *S* ca fiind $S=\{(x,y)\in R^2 \mid y=3x^2+4x-2\}$. *S* va putea fi reprezentat ca fiind tuplul *(3,4,-2)*, ceea ce codifică întreaga informaţie necesară pentru a reconstitui toate punctele *(x,y)* aparţinătoare lui *S*. Să presupunem acum o unitate de cunoaştere *a=(1,5)* şi o unitate de cunoaştere *b=(3,4,-2)*. Dacă interpretăm *a* ca fiind o pereche în R^2 şi *b* ca fiind parametri ce reprezintă setul infinit *S*, putem spune că $a \prec b$, deoarece unitatea de cunoaştere *b* cuprinde nu doar pe *a*, ci un întreg set de perechi care respectă aceeaşi relaţie. Observaţi că am putea avea de asemenea şi o unitate de cunoaştere *c=(0,-2,1,5,2,18)*, care ar putea fi decodificată drept setul de perechi *T={(0,-2),(1,5),(2,18)}*, şi am avea de asemenea $a \prec b$ şi $a \prec c \prec b$. Acest exemplu este doar un indiciu pentru a înţelege mai bine natura operatorului de abstractizare. Modul în care s-a făcut codificarea setului *S* în tuplul *(3,4,-2)* poate fi privit ca un fel de operator de compresie a datelor. Fiecare unitate de cunoaştere *b* care poate fi extinsă la alte unităţi de cunoaştere a_i cu ajutorul unor interpretări particulare se spune că este o generalizare a acestora, iar a_i se spune că sunt specializări ale lui *b*.

2.2. Operatorii elementari de cunoaştere

Prezentăm în continuare setul minim de operatori propus de Gudwin [5] ca formând fundamentul conceptual pentru construirea sistemelor inteligente. Aceştia sunt operatorii sau, mai precis, clasele de operatori numite: **extracţia cunoaşterii, generarea cunoaşterii şi selecţia cunoaşterii**. Există o strânsă legătură între aceşti operatori de cunoaştere elementari şi operatorii clasici de raţionament, adică deducţia, inducţia şi abducţia.

Astfel, de exemplu, operatorul de extragere a cunoaşterii poate fi asociat cu o deducţie generalizată, în sensul că el cuprinde tot ce însemna operatorul tradiţional de deducţie, dar în plus permite orice tip de unitate de cunoaştere ca şi intrare.

La fel stau lucrurile cu inducţia generalizată, care include şi unii operatori ce nu sunt acceptaţi în mod normal ca efectuând „inducţie”. În acest sens operatorul de generare a cunoaşterii generalizează ideea de inducţie pentru a include orice tip de procedură care generează unităţi de cunoaştere care sunt mai abstracte decât intrările.

În fine, selecţia cunoaşterii poate fi comparată cu operatorul standard de abducţie. Abducţia este adeseori privită ca fiind inferenţa ce duce la explicaţia „cea mai bună”. Acea parte ce are de-a face cu generarea unui set de ipoteze este în mod clar o inducţie (sau, mai bine spus, o inducţie generalizată). Munca abductivă constă de fapt în evaluarea şi selecţia celei mai bune ipoteze.

- **Extragerea cunoaşterii şi deducţia**

Presupunem o unitate de cunoaştere *a* şi o unitate de cunoaştere *b*, astfel încât $a \prec b$. Atunci o funcţie *fec* care reprezintă imaginea lui *b* (ţinând cont că b este o structură, cum ar fi de exemplu un număr structurat) în *a*: *a=fec(b)* se numeşte operator de extragere a cunoaşterii.

În figura 4 am reprezentat un exemplu de extragere de cunoaştere. Dintr-un set P de unităţi de cunoaştere, numit „premisă”, operatorul extrage un set C de unităţi de cunoaştere numite „concluzie”. Numim această operaţie extragere de cunoaştere deoarece definiţia extensivă a unităţilor de cunoaştere în C este un subset al definiţiei extensive de unităţi de cunoaştere în P. Astfel se „extrage” din P doar o parte din conţinutul său semantic.

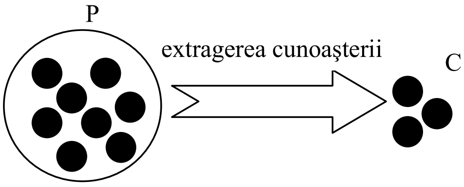

Fig. 4. Extragerea cunoaşterii

Cea mai obişnuită formă deductivă este aplicarea lui *modus ponens*, ca în exemplul clasic de mai jos:
Dacă toţi oamenii sunt muritori şi Socrate e om rezultă că Socrate e muritor, ceea ce s-ar putea scrie simbolic:

$om(x) \rightarrow muritor(x)$
$om(Socrate)$

$muritor(Socrate)$

În acest caz cunoaşterea că Socrate e muritor este conţinută de asemenea şi în premisa că toţi oamenii sunt muritori şi cea că Socrate este om. Astfel, $muritor(Socrate) \prec \{om(x) \rightarrow muritor(x) \wedge om(Socrate)\}$

Propoziiile sunt unităţi de cunoaştere statice, numite dicente, în sensul că ele există doar ca şi date (- spre deosebire de tipurile de cunoaştere dinamice, cum sunt argumentele, şi care nu există doar ca date, ci realizează de asemenea transformări în sistem). De obicei deducţia se aplică doar la cunoaşterea statică. Observăm că definiţia operatorului de extragere de cunoaştere permite şi includerea altor tipuri de cunoaştere, de vreme ce generalizează orice operaţie care explicitează cunoaşterea ce există deja în premise. În acest sens putem numi operaţia de extragere de cunoaştere drept deducţie generalizată.

Să observăm şi cum calculul unei funcţii este similar cu modus ponens: Cunoscând $f(x)$ şi de asemenea x_0, deducem $y_0=f(x_0)$. Astfel deducţia generalizată face exact ceea ce-i trădează numele, şi anume generalizează ideea de deducţie la alte tipuri de unităţi de cunoaştere.

➢ **Generarea cunoaşterii şi inducţia**

Presupunem din nou o unitate de cunoaştere *a* şi o unitate de cunoaştere *b*, astfel încât $a \prec b$ şi o funcţie *fgc* care reprezintă imaginea lui *a* pe *b*, deci: $b=fgc(a)$. În acest caz *fgc* este numit operator de generare a cunoaşterii. De obicei acest operator nu este de tipul intrare unică/ieşire unică, ci conţine un set de unităţi de cunoaştere de intrare şi un set corespunzător de unităţi de cunoaştere de ieşire. Astfel, avem de exemplu situaţia: $(b_1,\ldots,b_m) = fgc(a_1,a_2,\ldots,a_n)$.

În figura 5 premisa P este colecţia de unităţi de cunoaştere a_i şi concluzia C este colecţia de unităţi de cunoaştere b_i. Caracteristica de bază a acestui operator este faptul că definiţia extensivă a unităţilor de cunoaştere din C conţine neapărat elemente care iniţial nu au fost conţinute în definiţia extensivă a unităţilor de cunoaştere din P, ci au fost adăugate pe parcursul procesului de generare a cunoaşterii. Acest lucru se poate realiza fie prin combinarea unităţilor de cunoaştere, fie prin fuzionarea acestora sau transformarea, interpolarea, expansiunea topologică etc. (exemple: interpolarea funcţiilor, expansiunea topologică de la un număr la un set fuzzy etc.).

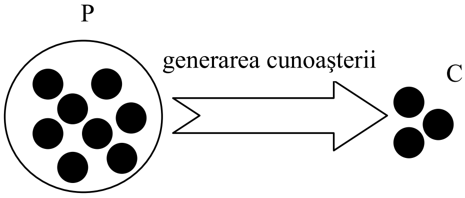

Fig. 5. Generarea cunoaşterii

Se ştie că inducţia este procesul care generează o lege generală pe baza unor observaţii particulare, astfel că acestea devin instanţe particulare a respectivei teorii generale. Este deci vorba de un proces dinspre particular către universal, dinspre concret către abstract. Acest proces se numeşte generalizare. Procesul principal de inducţie porneşte cu un set de exemple (de propoziţii, concepte etc.), care conduce la conceptul general care trebuie generat prin mai multe tehnici posibile. Acest lucru este similar cu procedura numită mai sus generarea cunoaşterii, cu o singură diferenţă: În generarea cunoaşterii nu trebuie ca unităţile de cunoaştere generate să fie neapărat o generalizare a exemplelor. Exemplele sunt utilizate doar ca un indicator către orice procedură care le foloseşte pentru a genera noi unităţi de cunoaştere. Astfel, de exemplu, procedurile de încrucişări şi mutaţii genetice dintr-un algoritm genetic pot fi incluse în generarea cunoaşterii, cu toate că în general acele procese nu se consideră a fi inducţie. În acest caz generarea cunoaşterii nu va putea fi numită inducţie propriu-zisă, ci o formă de inducţie generalizată.

➢ **Selecţia cunoaşterii şi abducţia**

Presupunem acum că avem un set de unităţi de cunoaştere $(a_1,a_2,...,a_n)$ şi un set de candidaţi pentru ieşire $(b_1,b_2,...,b_m)$. Presupunem de asemenea o funcţie *fsc* care face o selecţie între candidaţi: $b=fsc(a_1,a_2,...,a_n, c_1,c_2,...,c_m)$, în sensul că b este una dintre valorile c_i, iar valorile a_i sunt utilizate pentru a evalua şi a putea face o alegere între c_i-uri. În acest caz *fsc* se numeşte operator de selecţie a cunoaşterii.

În figura 6 unităţile de cunoaştere a_i aparţin unui set P(premise), iar candidaţii c_i aparţin unui set H (numit set de ipoteze). Unităţile de cunoaştere b_i (mai multe în acest caz) sunt selectate dintre c_i-uri şi sunt indicate prin C (concluzie). Să observăm că există acel caz particular când în H există un singur candidat c_i. În acest caz selecţia devine validare sau, în caz că unităţile de cunoaştere din P nu vor putea fi utilizate pentru a valida noua unitate de cunoaştere pentru a fi ieşirea C, nu se va produce nici o ieşire.

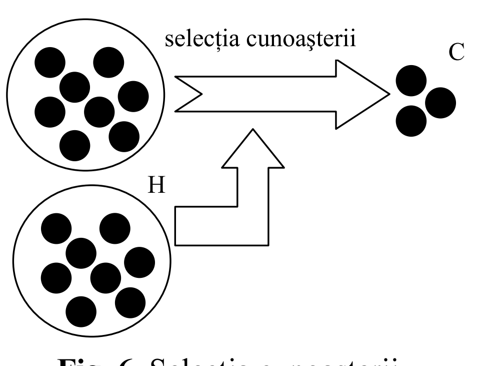

Fig. 6. Selecţia cunoaşterii

Abducţia, introdusă în logica modernă de către filozoful Charles Peirce [7,8], este metoda de raţionament cea mai puţin studiată până în prezent şi adesea nu prea bine înţeleasă. Practic, diferiţi cercetători au subliniat diferite aspecte ale abducţiei. Astfel, unii autori au înţeles abducţia ca pe inversul deducţiei, alţii s-au concentrat asupra întregului proces de explicare a raţionamentului, ceea ce include detecţia anomaliilor, verificarea ipotezelor şi selecţia celei mai bune ipoteze (a se vedea lucrarea [6]).

Un exemplu de raţionament ce utilizează abducţia ar fi următorul:

Deoarece calculatorul nu porneşte şi ştiind că dacă nu este curent la reţea calculatorul nu porneşte, rezultă, conform abducţiei, că nu este curent la reţea. Desigur motivul pentru care calculatorul nu porneşte ar putea fi şi altul, şi de aceea această metodă nu este o tehnică inferenţială validă.

Abstractizând ceea ce se întâmplă de fapt în cazul abducţiei s-a ajuns la concluzia că abducţia generalizată trebuie înţeleasă ca un pas de selecţie/validare. Astfel Gudwin [4,5] a propus înţelegerea abducţiei nu ca un proces de detecţie a anomaliilor (proces care ar consta practic mai mult din raţionamente deductive), nici ca un proces care generează ipoteze (ceea ce ar fi mai mult nişte raţionamente inductive), ci mai degrabă ca testarea şi selectarea acelor ipoteze.

3. Construirea sistemelor inteligente

Utilizând reţele obiectuale este posibil a se crea sisteme în care unităţile de cunoaştere sunt explicitate cu ajutorul obiectelor şi în mod deosebit unităţile de cunoaştere argumentative sunt obiecte active.

Astfel, într-o reţea obiectuală unităţile de cunoaştere sunt reprezentate prin intermediul unor obiecte, adică nişte unităţi elementare ce sunt în acelaşi timp şi date şi cod, plasate în anumite locaţii în reţea. Figura 7 prezintă o mică secţiune dintr-o reţea obiectuală.

Obiectele din locaţia activă din figura 7 sunt obiecte capabile să execute calcule. Ele fac o selecţie între obiectele din locaţiile de intrare, utilizează informaţiile din acestea pentru a construi alte obiecte şi a modifica propria lor structură şi eliberează noile obiecte create (sau transportă un obiect de intrare) în locaţiile de ieşire. Obiectele utilizate pot fi lăsate din nou în locaţiile de intrare, pot fi distruse sau pot fi transportate în locaţiile de ieşire.

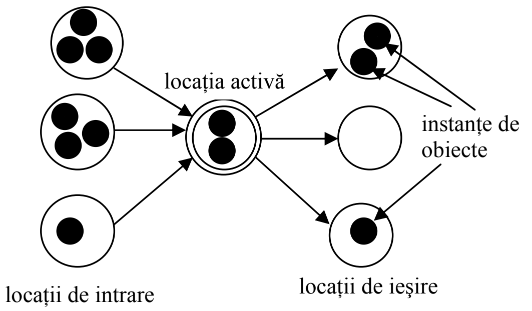

Fig. 7. Secţiune dintr-o reţea obiectuală

Două funcţii principale sunt implicate în acest proces: Prima este selecţia funcţiilor, care stabileşte obiectele care să fie utilizate ca sursă de informaţie, iar a doua este funcţia internă, care ia această informaţie împreună cu informaţia din interiorul structurii propriului obiect activ şi o utilizează pentru a genera un nou obiect. Din punct de vedere conceptual atât funcţia de selecţie cât şi funcţia internă pot fi orice fel de funcţie. Acest lucru face ca obiectul activ să fie o reprezentare perfectă a cunoaşterii argumentative, capabile să efectueze fiecare sau toate din cele trei strategii de raţionament generalizate: deducţia, inducţia şi abducţia. Funcţia de selecţie va efectua rolul abducţiei şi funcţia internă va prelua rolul deducţiei şi inducţiei. Acest fapt face ca reţelele obiectuale să fie un instrument foarte bun de reprezentare şi modelare a sistemelor inteligente.

O proprietate interesantă a unei reţele obiectuale este aceea că un obiect activ poate genera un alt obiect activ în acelaşi loc sau într-o altă locaţie în reţea. În acest caz partea activă a reţelei este posibil să fie modificată, mărită sau micşorată dinamic, datorită comportamentului reţelei. Această proprietate permite modelarea de sisteme care sunt capabile să-şi schimbe propria structură, ca sisteme de învăţare şi sisteme adaptive. Exemple de reţele obiectuale care să implementeze sisteme fuzzy, reţele neuronale şi algoritmi genetici sunt prezentate în lucrarea [4].

4. Concluzie

Această lucrare a prezentat unele concepte introduse relativ recent (în ultimii 10 ani) în filozofia cunoaşterii şi în domeniul mai nou al semioticii numerice. S-a insistat în mod deosebit asupra noilor concepte de deducţie, inducţie şi abducţie generalizate, acestea fiind propuse de unii cercetători drept componente elementare pe care să se bazeze construcţia sistemelor inteligente universale şi în mod special sistemele semiotice.

Bibliografie

1. Chandler, Daniel, *Semiotics for Beginners*, http://www.aber.ac.uk/media/Documents /S4B/sem02.html
2. Albus, J., *Outline for a Theory of Intelligence*, IEEE Transactions on SMC, vol.21, n.3, Mai-June 1991
3. Meystel, A., *Semiotic Modeling and Situation Analysis: An Intreoduction*, AdRem Inc., 1995
4. Gudwin R.R., Gomide, F.A:C., *Computational Semiotics: An Approuch for the Study of Intelligent Systems – Part II Theory and Applications*, Technical Report RT-DCA09 – DCA-FEEC-UNICAMP, 1997
5. Gudwin, R.R., *On the Generalized Deduction, Induction and Abduction as the Elementary Reasoning Operators within Computational Semiotics*, Technical Report RT-DCA09 – DCA-FEEC-UNICAMP, 1997
6. Muntean M., Muntean C., *Reasoning Methods Used in AI: Some Philosophical, Theoretical and Practical Aspects*, Proceedings of the International Workshop IE&SI, 26-27 mai 2006, Timisoara, Editura Mirton, 2006
7. Yu, C.H., *Abduction, Deduction, and Induction: Their implications to quantitative methods*, 2005, Eprint: http://seamonkey.ed. asu.edu/ ~alex/teaching/WBI/
8. Yu, C.H., *Is there a Logic of Exploratory Data Analysis?*, Annual Meeting of American Educational Research Association, New Orleans, LA, April, 1994, Eprint http://seamonkey.ed.asu.edu/~alex/ pub/Peirce