

DESCOPERIREA DE CUNOȘTINȚE DIN BAZE DE DATE SPAȚIALE

Mirela Danubianu*

În perioada ultimilor ani am asistat la un proces de stocare a unor cantități uriașe de date, în baze de date, depozite de date, sisteme informaționale geografice sau sub alte forme. Este evident faptul că, în prezent, aceste cantități de date cresc cu o viteză uluitoare.

Numeroase organizații și-au construit depozite de date capabile să stocheze sute de teraocteți de date cu privire la explorarea resurselor naturale; bazele de date din domeniul astronomiei au dimensiuni de ordinul teraocteților; se estimează că sistemele de observare a Pământului pot transmite până la 50 gigaocteți pe oră. Aceste aspecte au constituit o provocare pentru metodele tradiționale de analiză a datelor capabile să extragă informații și cunoștințe.

În contextul dat, explorarea datelor (DM - data mining) și descoperirea cunoștințelor din date (KDD - knowledge discovery in databases) s-au impus ca domenii de cercetare de mare interes. În esență, *acestea implică descoperirea de cunoștințe interesante, anterior necunoscute și implicite din baze mari de date* [FPSU96], și se află la confluența mai multor domenii de cercetare, incluzând învățarea automată, sisteme de baze de date, statistică, recunoașterea formelor și teoria informației.

În afara numeroaselor studii de descoperire a cunoștințelor din bazele de date relaționale, sau din bazele de date de tranzacții, explorarea datelor spațiale (spatial data mining), care se referă la *extragerea cunoștințelor implicite, a relațiilor spațiale sau a altor tipare care nu sunt explicit memorate în bazele de date spațiale*, a făcut obiectul a numeroase studii de cercetare [EKX95][KN96][KH95][ZRL96].

Datele spațiale au o serie de caracteristici care le disting de bazele de date relaționale. În principal este vorba despre faptul că acestea conțin informații topologice sau de distanță, folosesc structuri de indexare spațiale multidimensionale, sunt accesate prin metode de acces specifice și solicită adesea calcule geometrice și tehnici spațiale de reprezentare a cunoștințelor. Ca urmare, explorarea datelor spațiale necesită integrarea tehnologiilor de explorare a datelor cu cele specifice bazelor de date spațiale. Una din problemele delicate ale explorării datelor spațiale este aceea a eficienței tehnicilor folosite, datorită faptului că se lucrează cu volume importante de date de tipuri complexe și cu metode de acces spațiale.

Explorarea datelor spațiale poate fi utilizată pentru vizualizarea bazelor de date spațiale, pentru înțelegerea acestui tip de date, pentru a descoperi legăturile spațiale și relația dintre datele spațiale și cele non-spațiale, pentru reorganizarea bazelor de date spațiale, optimizarea interogărilor spațiale, etc. Rezultatele acestor cercetări își găsesc aplicația în sistemele informaționale geografice, în explorarea bazelor de date de tipul imaginilor, în navigație sau în orice alte domenii care lucrează cu date spațiale.

Această lucrare se dorește a fi o scurtă trecere în revista a metodelor de explorare a datelor spațiale, a tehnicilor utilizate, cu plusurile și minusurile lor, cu modurile lor de aplicare și cu provocările cărora trebuie să le facă față.

* Universitatea "Ștefan cel Mare" Suceava, Facultatea de Inginerie Electrică

Utilizarea tehnicilor de explorare a bazelor de date relaționale

Una din primele încercări de analiză a datelor spațiale a fost realizată în 1993 de către Major et al. [MM93] care au utilizat un instrument comercial pentru a explora o bază de date referitoare la o furtună tropicală, în scopul de a prezice dacă aceasta va atinge teritoriile Statelor Unite ale Americii. Datele prin care se descria uraganul au fost descompuse în observații în diferite puncte, iar aceste observații au fost memorate într-o bază de date relațională. Au fost folosite atribute de tipul: poziția uraganului, viteza, direcția de deplasare, unghiul față de coastă, etc. Deoarece descrierea uraganului în diferite puncte a fost memorată prin intermediul mai multor tuple, anumite date au fost interdependente. Aceste interdependențe au provocat o serie de neajunsuri deoarece algoritmul folosit presupunea independența datelor. Ca suport al selecției pentru cele mai bune reguli a fost utilizat un sistem GIS.

Concluziile acestui studiu au fost acelea că este necesară extinderea tehnicilor tradiționale de explorare a datelor către explorarea datelor spațiale pentru o analiză corespunzătoare a obiectelor și a fenomenelor spațiale complexe.

Procesul descoperirii de cunoștințe din bazele de date spațiale

Experiența ultimilor câțiva ani a arătat faptul că descoperirea cunoștințelor din baze de date uriașe implică mai mult decât simpla aplicare a algoritmilor sofisticăți de explorare a datelor pe un set predefinit de date.

Una din problemele majore în cercetările legate de descoperirea cunoștințelor din date este aceea a înțelegerii KDD ca un "*proces netrivial de identificare a tiparelor valide, cu caracter de noutate, potențial folositoare și în ultimă instanță posibil de înțeles, din date.*" [FPS96]

Din acest punct de vedere, noțiunea de tipar este înțeleasă într-un sens foarte general. Un tipar este tot ceea ce un algoritm de explorare a datelor poate extrage sau poate genera din date, cum ar fi un model care clasifică pe baza unui arbore de decizie sau a unei rețele neuronale, o grupare de date sau o mulțime de reguli de asociere.

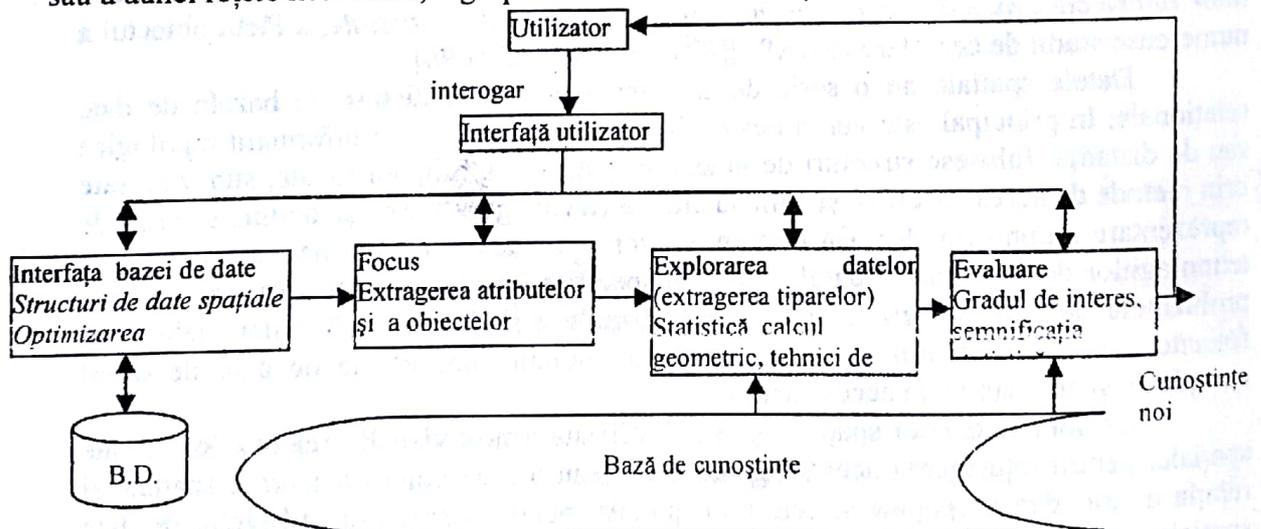


Figura 1 Modelul procesului de descoperire a cunoștințelor din date spațiale

Procesul de descoperire a cunoștințelor din date spațiale poate fi modelat prin arhitectura[†] prezentată în figura 1.

[†] Adaptare după Matheus, C.J., Chan, P.K., și Piatetsky-Shapiro, G. Systems for Knowledge Discovery in Databases. IEEE Transaction Knowledge and Data Engineering 5,5 (oct. 1993), 903-913

Experiența acumulată a dus la concluzia că procesul descoperirii cunoștințelor nu se reduce la o „simplă apăsare a unui buton”, ci din contră este complex, iterativ și puternic interactiv. În fiecare din etapele sale se face simțită prezența omului prin utilizatorul (sau analistul) care decide în ce va consta următoarea fază, dacă va fi reluată faza curentă sau chiar dacă se va face o întoarcere un pas înapoi la o fază anterioară.

Pe scurt, descoperirea cunoștințelor se realizează astfel: cunoștințele de fond, cum ar fi ierarhia de concepte spațiale și non-spațiale sau informațiile legate de baza de date sunt memorate în baza de cunoștințe. Datele sunt extrase de pe mediul de stocare prin intermediul *interfeței bazei de date* care permite, printre altele, optimizarea interogărilor. Pot fi folosiți indecși pentru datele spațiale, în scopul procesării eficiente. *Componenta de focalizare* decide care sunt acele părți ale datelor utile pentru recunoașterea tiparelor. Spre exemplu, se poate decide că numai anumite atribute sunt relevante pentru sarcina de descoperire a cunoștințelor sau se pot extrage obiecte a căror utilizare garantează rezultatele cele mai bune. Regulile și tiparele sunt descoperite în etapa aplicării tehnicilor de *explorare a datelor* realizată de modulul cu același nume. Acesta poate utiliza procedee statistice, metode de învățare automată și tehnici de clasificare și grupare în conjuncție cu algoritmi de calcul geometric, pentru descoperirea de reguli sau legături. Importanța și semnificația tiparelor descoperite este stabilită cu ajutorul modulului de *evaluare* care are posibilitatea de a elimina cunoștințele deja existente sau redundante. Cunoștințele descoperite sunt oferite în final utilizatorului pentru a fi verificate.

Metode și tehnici de explorare a datelor folosite

Cunoștințele descoperite din bazele de date spațiale pot îmbrăca diverse forme, și anume: reguli caracteristice pentru descrierea datelor spațiale, reguli discriminante pentru a diferenția o clasă de date spațiale de alte clase, reguli de asociere care asociază una sau mai multe caracteristici unui set distinct de caracteristici, reguli de deviație și de evoluție pentru descrierea schimbărilor în timp sau reguli care descriu structuri deosebite. Toate acestea pot fi prezentate sub diferite forme și pot fi utilizate pentru a descrie obiectele spațiale.

Deoarece explorarea datelor impune numeroase aspecte provocatoare pentru cercetare, aplicarea directă a metodelor și tehnicilor dezvoltate de domenii înrudite precum învățarea automată, statistica sau bazele de date nu pot rezolva problemele apărute. În acest scop este necesară efectuarea de studii dedicate pentru a găsi noi metode sau tehnici integrate pentru o explorare eficientă. Ca urmare a acestui fapt, explorarea datelor (data mining) s-a constituit ea însăși într-un domeniu aparte de cercetare.

În calitate de componentă a procesului de descoperire a cunoștințelor din date, explorarea datelor implică aplicarea iterativă a unor metode specifice, în particular a unor algoritmi specifici.

Se pot distinge două tipuri de obiective, ale acestei etape, și anume: *verificarea*, caz în care sistemul este folosit pentru a verifica ipotezele utilizatorului și *descoperirea* atunci când sistemul găsește, în mod autonom noi tipare. Mai departe, descoperirea poate fi divizată în: *predicție* dacă sistemul găsește tipare în scopul predicției comportamentului viitor pentru anumite entități sau *descriere* atunci când sistemul găsește tipare în scopul prezentării acestora unui utilizator, într-o formă inteligibilă.

Obiectivele predicției respectiv ale descrierii sunt realizate prin intermediul următoarelor metode primare de explorare a datelor:

- **clasificarea** : găsirea unei funcții care include un articol de date într-una din mai multe clase predefinite.
- **regresia**: este utilizată la prezicerea unei valori a unei variabile continue bazată pe valorile altor variabile, presupunând un model de dependență liniar sau neliniar. Regresia logică este utilizată pentru precizarea valori unei variabile binare. Este un instrument de clasificare care este utilizat la precizarea valorii unei variabile, cum ar fi de exemplu, "dacă un individ este cumpărător sau nu", deasemenea este utilizată la precizarea variabilelor continue, cum ar fi: "probabilitatea că un individ va face cumpărături".
- **gruparea** (clustering-ul): identifică o mulțime finită de categorii sau cluster-e pentru a descrie datele. Strâns legată de acesta este metoda estimării densității de probabilitate care constă în tehnici de estimare din date a funcției de probabilitate asociată pentru toate variabilele/câmpurile unei baze de date.
- **rezumarea**: găsește o descriere compactă pentru o submulțime de date.
- **modelarea dependențelor**: găsește un model care descrie dependențele semnificative dintre variabile.
- **detectarea schimbărilor și a deviației** : descoperă cele mai semnificative schimbări produse în date în intervalul dintre două măsurări consecutive.

Se poate face o clasificare după fundamentul căii de explorare a datelor în explorare pe baza de generalizare, explorare bazată pe tipare, explorare bazată pe teorii matematice și statistice, acces integrat etc

Explorarea pe bază de generalizare

Datele și obiectele din bazele de date conțin adesea informații detaliate la nivelul conceptelor primitive. În acest caz este de dorit să facă o rezumare a mulțimilor de date pentru prezentarea acestora prin concepte de nivel superior. Se pot, spre exemplu, rezuma datele detaliate despre temperaturi și precipitații dintr-o regiune în scopul prezentării tiparului general al vremii. Aceasta implică o explorare a datelor bazată pe generalizare, caz în care în prima fază are loc o abstractizare a unui volum considerabil de date relevante de la un concept de nivel scăzut la unul de nivel relativ ridicat, după care se realizează extragerea cunoștințelor din datele generalizate. În această situație se impune existența cunoștințelor fundamentale în forma unei ierarhii de concepte, care este fie furnizată explicit de experții în domeniu, fie poate fi generată automat prin analiza datelor.

În cazul bazelor de date spațiale pot fi definite două categorii de ierarhii de concepte: *non-spațiale și spațiale*. Odată cu impunerea ierarhiilor de concepte, informația devine din ce în ce mai generală, dar este încă consistentă la nivelul conceptelor inferioare. În cazul datelor spațiale, un exemplu de ierarhie în procesul de generalizare ar fi următorul: regiunile reprezentând unități teritorial-administrative pot fi unite în județe, iar acestea la rândul lor pot fi unite în state ș.a.m.d.

Inducția orientată spre attribute este o tehnică eficientă de generalizare a datelor [FPSU96]. Se consideră mai întâi o interogare de explorare a datelor exprimată într-un limbaj similar SQL, (de exemplu DMSQL) care colectează setul de date relevante într-o bază de date. Apoi generalizarea este realizată prin creșterea ierarhiei de generalizare și rezumarea legăturilor dintre datele spațiale și cele non-spațiale la concepte de nivel superior. În cazul datelor non-spațiale aceasta se realizează prin: ridicarea ierarhiei de concepte când valorile atributelor dintr-un tuplu sunt înlocuite prin valorile generalizate, prin eliminarea atributelor atunci când continuarea generalizării este imposibilă și există prea multe valori distincte pentru un atribut și prin cuplarea

tuplurilor identice. Inducția continuă până când toate atributele sunt generalizate până la nivelul dorit. Pe durata procesului de unire a tuplurilor identice numărul tuplurilor cuplate este memorat ca un contor. Suplimentar pot fi memorate valorile agregate ale unor atribute cantitative pentru a face posibilă prezentarea cantitativă a cunoștințelor obținute.

Datele generalizate pot fi exprimate sub forma unor relații generalizate sau cuburi de date asupra cărora pot fi aplicate alte operații în scopul transformării lor în diverse forme de cunoștințe. Spre exemplu operațiile de "drill-down" respectiv de "roll-up" permit vizualizarea datelor la diferite nivele de abstractizare; relațiile generalizate pot fi transpuse în tabele rezumate, hărți sau diagrame în scopul vizualizării și prezentării, pot fi extrase reguli caracteristice sau reguli discriminante, etc.

Inducția orientată spre atribute a fost extinsă și asupra datelor spațiale. În [LHC93] sunt prezentați doi algoritmi de generalizare: în cazul dominanței datelor spațiale respectiv în cazul dominanței datelor non-spațiale.

Algoritmul de generalizare în cazul dominanței datelor spațiale permite descrierea regiunilor din spațiu cu ajutorul predicatelor de nivel înalt. În primul rând sunt unite regiunile în concordanță cu ierarhiile spațiale ceea ce conduce la o hartă cu un număr redus de zone. Apoi, se realizează o descriere non-spațială a fiecărei zone cu utilizând tehnica inducției orientate pe atribute. Răspunsul unei interogări este descrierea tuturor regiunilor cu ajutorul disjuncției câtorva predicate care caracterizează fiecare din regiunile generalizate.

Algoritmul de generalizare pentru date dominante non-spațiale crează hărți care constau dintr-un număr mic de regiuni care se află pe același nivel ierarhic al descrierii non-spațiale. Acest algoritm începe cu inducția orientată către atribute non-spațiale și generalizarea acestora către nivele conceptuale mai înalte. Apoi zonele învecinate având aceleași valori pentru atributele generalizate sunt unite. Se poate utiliza aproximarea pentru a ignora regiunile reduse cu descrieri non-spațiale diferite. În figura următoare este ilustrat un exemplu al aplicării algoritmilor menționați. Este prezentată interogarea formulată în algoritmul de generalizare cu dominanță spațială precum și rezultatul obținut.

Extract characteristic rule
from harta_temperaturi
where provincia="XX" and
perioada="vara" and anul=1999
in relevance to regiune and
temperatură

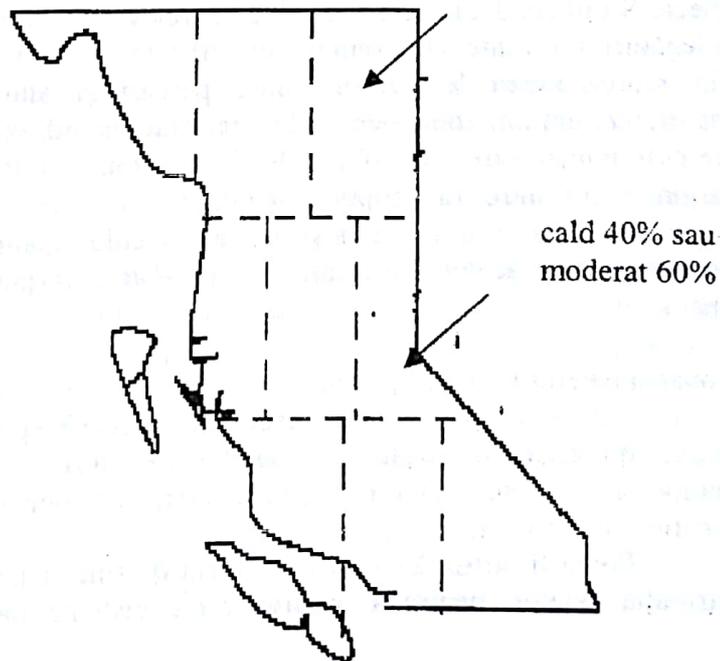


Figura 2. Interogarea și rezultatul obținut în urma aplicării algoritmului de generalizare cu dominanță spațială

Explorarea asocierilor spațiale

Metoda amintită anterior permite găsirea regulilor caracteristice care descriu obiectele spațiale din punct de vedere al atributelor lor non-spațiale. Sunt cazuri în care, însă, se dorește descoperirea regulilor de asociere spațiale, care sunt acele reguli care asociază unul sau mai multe obiecte spațiale cu alte obiecte spațiale.

Conceptul de reguli de asociere a fost introdus în 1993 [AIS93] pentru explorarea bazelor de date de tranzacții de dimensiuni mari, iar în 1995 [KH95] a fost extins la bazele de date spațiale.

O regulă de asociere spațială se notează :

$$X \rightarrow Y (c\%)$$

unde: X și Y sunt mulțimi de predicate spațiale sau non-spațiale iar
c% este gradul de încredere (confidența) regulii

Un exemplu de astfel de regulă este următoarea:

$$\text{este}(x, \text{\textit{școală}}) \wedge \text{\textit{aproape_de}}(x, \text{\textit{centru_sportiv}}) \rightarrow \text{\textit{aproape_de}}(x, \text{\textit{parc}}) (80\%)$$

Această regulă afirmă că 80% din școlile care sunt aproape de un centru sportiv sunt de asemenea aproape de un parc. Există diferite tipuri de predicate spațiale care pot genera reguli de asociere spațiale, printre care: relații topologice precum *intersecția*, *suprapunerea*, *disjuncția* etc., sau informații de distanță, precum *aproape_de*, *îndepărtat_de*, etc.

În bazele de date mari pot exista numeroase asociații între obiecte dar cele mai multe din acestea, fie sunt aplicabile doar unui număr redus de obiecte, fie au un grad de încredere redus.

Spre exemplu, un utilizator poate să nu fie interesat de o relație care asociază 5% din case cu o anumită școală, dar poate fi interesat de o regulă care se aplică cel puțin la 50% din case. Există două praguri, *suportul minim și gradul minim de încredere* care sunt utilizate pentru controlul filtrării asocierilor care descriu un procent mic de obiecte sau regulile cu confidență redusă. Aceste praguri pot fi diferite la fiecare nivel al descrierilor non-spațiale ale obiectelor, deoarece utilizarea aceluiași prag poate să nu găsească asociațiile interesante la nivel ierarhic redus pentru că numărul obiectelor care satisfac același predicat poate fi destul de mic.

Procesul de explorare este inițiat printr-o interogare care descrie o clasă de obiecte S utilizând alte clase de obiecte relevante pentru sarcina propusă și o mulțime de legături relevante. De exemplu, un utilizator poate dori să descrie parcurile unui oraș prin reprezentarea legăturilor dintre parcuri și alte obiecte precum: căi ferate, restaurante, grădini zoologice, străzi etc. Mai curând, utilizatorul poate stabili că este interesat numai care sunt obiectele dintr-o zonă cu lățimea de un kilometru de la marginile parcului. În scopul minimizării costului calculelor spațiale, algoritmul utilizează diferite aproximări și aplică calculul spațial mai detaliat, dar mult mai costisitor, numai acelor tipare care au un suport corespunzător la nivelul de aproximație considerat.

Gruparea datelor (Data Clustering)

Gruparea spațială, care asociază obiectele spațiale similare în clase, este o tehnică importantă de explorare a datelor, care poate fi utilizată în scopul identificării zonelor de exploatare similară a resurselor, în fuzionarea regiunilor cu caracteristici climatice similare, etc.

Poate fi utilizată ca un instrument de sine stătător pentru a înțelege mai bine distribuția datelor, pentru a observa caracteristicile fiecărui grup și pentru a ușura

focalizarea asupra unei anumite mulțimi de grupuri pentru analize ulterioare, sau, poate fi un pas de pregătire pentru algoritmi de clasificare sau de caracterizare care operează asupra grupurilor detectate.

Urmare a faptului că analiza grupurilor a fost un domeniu de cercetare activ în explorarea datelor, în ultimii ani au fost dezvoltate metode eficiente de grupare. Acestea pot fi clasificate în: metode de partiționare [KR90][NH94][BFR98], metode ierarhice [KR90] [ZRL96] [GRS98] [KHK99], metode bazate pe densitate [EKX96] [ABKS99] [HK98], metode bazate pe grilă [WYM97] [SCZ98] [AGGR98] și metode bazate pe model [SD90] [KOH82].

Utilizarea aproximărilor și a agregărilor

Metodele de grupare pot oferi răspunsuri la întrebări de genul "unde sunt poziționate grupurile în bazele de date spațiale". Există însă și un alt aspect al problemei, și anume "de ce se găsesc grupurile acolo". Acesta poate fi reformulat astfel: care sunt caracteristicile grupurilor, prin prisma proprietăților sau a obiectelor pe care le conțin acestea. Problema care se pune este legată de modul de măsurare a proximității agregării deoarece o afirmație de genul "90% din casele din grup posibil să aibă caracteristica X" este mai interesantă și conține mai multă informație decât afirmația "o casă are cu siguranță caracteristica X". Proximitatea agregării este măsura apropierii setului de obiecte din grup de o anumită caracteristică ca opusă distanței dintre granițele grupului și limitele unei caracteristici.

În [KN96] este prezentată o metodă care permite găsirea rapidă a unei caracteristici apropiată grupului.

Explorarea bazelor de date raster

Explorarea unor baze de date raster, precum cele de tipul imaginilor, este un caz particular al explorării datelor spațiale. Printre studiile în domeniu se numără POSS II (Second Palomar Observatory Sky Survey) care utilizează arborii de decizie pentru clasificarea galaxiilor, sau a altor obiecte cosmice pornind de la cca 3 teraocteți de imagini cosmice și studiul Magellan care analizează aproximativ 30000 de imagini radar de rezoluție înaltă ale suprafeței planetei Venus, în scopul identificării posibilităților vulcani.

Provocări pentru viitor

Este inutil, ca în anii de tranziție către societatea informațională se demonstreze necesitatea unui domeniu de cercetare precum cel al extragerii de cunoștințe din volume mari de date geografice.

Ceea ce trebuie însă menționat este faptul că există încă aspecte ale cercetării care necesită extinderea studiilor. Câteva din aceste aspecte se referă la: găsirea unor metode adiționale precum clasificarea, explorarea bazată pe tipare sau pe similarități special dedicate datelor geografice; analiza posibilităților de explorare interactivă a datelor folosind reacțiile vizuale, și analiza posibilităților de proiectare a unui limbaj dedicat explorării datelor spațiale; explorarea datelor provenite din surse distribuite (Internet/Intranet) și memorate în diferite formate. O certă provocare este combinarea metodelor de explorare a datelor spațiale cu bazele de date spațiale avansate (baze de date spațiale orientate obiect sau baze de date spațio-temporale) și cu tehnologia sistemelor expert pentru a crea așa-numitele sisteme GIS inteligente.

Concluzii

Am făcut în această lucrare o trecere în revistă a metodelor utilizate în explorarea datelor, văzută ca o etapă a procesului de descoperire a cunoștințelor din bazele de date spațiale. Este o temă actuală și în același timp atractivă care are ca scop să ofere sistemelor informaționale geografice puterea descoperirii cunoștințelor și să adapteze noile aplicații GIS cerințelor anilor ce vor veni.

REFERINȚE

- [ABKS99] Ankerst, M., Breunig, M., Kriegel, H.P., Sanders, J., *OPTICS: Ordering points to identify the clustering structure*. In Proc. 1998 ACM- SIGMOD Int. Conf. Management of Data (SIG-MOD'99) Philadelphia, 1999, 49-60
- [AIS93] Agrawal, R., Imielinski, T. and Swami, A. (1993) *Mining association rules between sets of items in large databases*. In Proceedings of the ACM SIGMOD International Conference on Management of Data (ACM SIGMOD 1993)9
- [AGGR98] Agrawal, R., Gehrke, J., Gunopulos, D., Raghavan, P., *Automatic subspace clustering of high dimensional data for data mining applications*. In Proc 1998 ACM-SIGMOD Int. Conf. Management of data (SIGMOD'98), Seattle, 1998, 94-105
- [BFR98] Bradley, R., Fayyad, U., Reina, C., *Scaling clustering algorithm for large databases* In Proc. 1998 Int. Conf. Knowledge Discovery and Data Mining (KDD'98) New York, 1998, 9-15
- [EKX95] Ester, M., Kriegel, HP., Xu, X., *Knowledge Discovery in Large Spatial Databases : Focusing Techniques for Efficient Class Identification*. In Advances in Spatial Databases, SSD'95, Springer-Verlag , Berlin, 1995, 67-82
- [EKSX96] Easter, M., Kriegel, H.P., Sander, J., Xu, X. *A density-based algorithm for discovering clusters in large spatial databases* In Proc. 1996 Int. Conf. Knowledge Discovery and Data Mining (KDD'96) Portland, 1996, 226-231
- [FPS96] Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P. (1996) *The KDD process for extracting useful knowledge from volumes of data*. Communications of the ACM, 39(11):27-34
- [FPSU96] Fayyad, U., Piatetsky-Shapiro, G., Smith, P., Uthurusamy, R., *Advances in Knowledge Discovery and Data Mining* AAAI/MIT Press, Menlo Park, CA, 1996.
- [GRS98] Guha, S., Rastogi, R., Shim, K., *Cune: An efficient clustering algorithm for large databases* In Proc 1998 ACM-SIGMOD Int. Conf. Management of Data (SIGMOD'98), Seattle, 1998, 73-84
- [HK98] Hinneburg, A., Keim, A., *An efficient approach to clustering in large multimedia databases with noise*. In Proc 1998 Int. Conf. Knowledge Discovery and Data Mining (KDD'98), New York, 1998, 58-65
- [KH95] Koperski, K., Han, J., *Discovery of Spatial Association Rules in Geographic Information Databases*, SDD'95 Springer-Verlag, Berlin, 1995, 47-66
- [KHK99] Karypis, G., Han, J., Kumar, V., *CHAMELEON: A hierarchical clustering algorithm using dynamic modeling*. COMPUTER, 32:68-75, 1999
- [KN96] Knorr, E., Ng, R. T., *Finding aggregate Proximity Relationship and Commonalities in Spatial Data Mining*. IEEE Transaction Knowledge and Data Engineering 1996, 884-897
- [KOH82] Kohonen, T., *Self organized formation of topologically correct feature maps*. Biological Cybernetics, 1982, 43:59-69
- [KR90] Kaufman, L., Rousseeuw, P.J., *Finding Groups in Data: an introduction to Cluster Analysis*, John Wiley & sons, 1990
- [LHC93] Lu, W., Han, J., Choi, B.C., *Discovery of General Knowledge in Large Spatial Databases* In Proc. Of Far East Workshop on Geographic Information Systems, Singapore, 1993, 275-289
- [MM93] Major, J., Mangano, J., *Selecting among Rules Induced from a Hurricane Database*. In Proc. 1993 Knowledge Discovery in Databases Workshop AAAI Press, 1993
- [NH94] Ng, R., Han, J., *Efficient and effective clustering method for spatial data mining* In Proc. 1994 Int. Conf. Very Large Data Bases (VLDB94), Santiago Chile, 1994, 144-155
- [SCZ98] Sheikholeslami, G., Chatterjee, S., Yhang, A., *WaveCluster: A multi-resolution clustering approach for very large spatial databases*, In Proc. 1998 Int. Conf. Very Large Data Bases (VLDB98), New York, 1998, 428-439
- [SD90] Shavlik, J.W., Dietterich, T.G., *Reading in Machine Learning*, Morgan Kaufmann, 1990
- [ZRL96] Yhang, T., Ramakrishnan, R., Livny, M., *BIRCH: an efficient data clustering method for very large databases*. In Proc 1996 ACM-SIGMOD Int. Conf. Management of Data, Montreal, 1996, 103-114
- [WYM97] Wang, W., Yang, J., Munty, R., *STING: A statistical information grid approach to spatial data mining*. In Proc 1997 Int. Conf. Very Large Data Bases (VLDB'97) Athenes, 1997, 186-195