

DATA MINING ÎN MANAGEMENTUL RELAȚIILOR CU CLIENȚII

Drd. Vasile - Bogdan Arcanu
Facultatea de Economie și Administrarea
Afacerilor Universitatea din Craiova
România
e-mail www.arcanubogdan@yahoo.com

Abstract

În contextul dezvoltării afacerilor mileniului trei, rapiditatea și adaptabilitatea la schimbare sunt cuvintele-cheie. Astfel pentru a face față concurenței tot mai puternice, informațiile, transmise în timp real, permit firmelor să anticipeze nevoile clienților lor și evoluțiile pieței mondiale. Organizațiile descoperă acum faptul că Peter Drucker a fost un vizionar afirmând că în centrul strategiei oricărei firme se află clientul. Noua economie presupune relații puternice și durabile cu clienții, modul de gestionare a acestora cu ajutorul noilor tehnologii ale informației constituind un element major al creșterii competitivității firmelor.

Cuvinte cheie:

Data mining, Managementul relațiilor cu clientii, machine learning

Machine learning este un domeniu al inteligenței artificiale ce implică dezvoltarea unor metode de a crea aplicații software pentru analiza seturilor de date pentru a permite calculatoarelor să „învețe” din experiența anterioară. *Machine learning* folosește intensiv statistica matematică, din moment ce ambele studiază interpretarea datelor. În funcție de tipul rezultatelor, algoritmii de *machine learning* sunt organizați în mai multe categorii, cum ar fi *supervised learning* care generează funcții ce pun în corespondență datele de intrare și ieșire, sau *unsupervised learning* în care algoritmii generează modele bazându-se pe datele existente.

Recunoașterea formelor sau clasificarea duce cu un pas înainte statistica matematică și *machine learning* prin efectuarea unei acțiuni în funcție de tipul datelor, folosind metode cum ar fi rețelele neuronale și rețelele bayesiene și având aplicații tipice în clasificarea textului și recunoașterea vorbirii și a imaginilor.

Aflându-se sub aceeași „umbrelă” cu inteligența artificială pentru numeroasele înțelesuri într-o gamă largă de contexte, *data mining* este cunoscută și sub numele de descoperirea cunoștințelor în bazele de date și folosește tehnici computaționale bazate pe inteligență artificială, *machine learning*, recunoașterea formelor și statistică matematică.

Data mining este un proces analitic ce

DATA MINING IN CUSTOMER RELATIONSHIP MANAGEMENT

Vasile-Bogdan Arcanu - PhD. Faculty of
Economics and Business Administration,
University of Craiova - Romania
e-mail www.arcanubogdan@yahoo.com

Abstract

In the context of millennium development business, speed and adaptability to change are the key words. So to meet increasingly strong competition, information, transmitted in real time, enable companies to anticipate their customers needs and developments in the global market. Organizations now find that Peter Drucker was a visionary in the center saying that any company is customer strategy. The new economy requires strong and lasting relationships with customers, how to manage them with new information technologies is a major element of increased competitiveness of firms.

Keywords:

Data mining, customer relationship management, machine learning

Machine learning is an area of artificial intelligence involves developing ways to create software to analyze data sets to enable computers to "learn" from past experience. *Machine learning* uses mathematical statistics intensive, since both studies and the interpretation of data. Depending on the results of *machine learning* algorithms are organized into several categories, such as *supervised learning* which results in correlation functions that make data input and output, or *unsupervised learning* algorithms that generate models basing on existing data.

Pattern recognition or classification step leads to a mathematical statistics and *machine learning* by performing an action depending on the type of data, using methods such as neural networks and Bayesian networks and with typical applications and speech recognition and text classification images.

Being under the same "umbrella" with many meanings artificial intelligence in a wide range of contexts, *data mining* is known as knowledge discovery in databases and use computational techniques based on artificial intelligence, *machine learning*, pattern recognition and Mathematical Statistics.

Data mining is an analytical process to explore a large number of data looking for patterns or relationships between variables, and then generalize these results in a model formula or decision tree, and

exploarează un număr foarte mare de date în căutarea unor șabloane sau relații între variabile, apoi generalizează aceste rezultate într-un model, formulă sau arbore de decizie și, în cele din urmă, verificarea corectitudinii modelului generat prin testarea lui pe setul de date existent sau al unuia nou. De cele mai multe ori, cu predilecție în aplicațiile economice, scopul acestui algoritm este de a găsi metode de previziune a evenimentelor și rezultatelor viitoare pe baza datelor existente, de a ajuta managerii să ia decizii repede și corect.

În alte situații, *data mining* poate fi folosită pentru a verifica dacă există o corelație ascunsă între datele de intrare și rezultate, sau dacă o asemenea corespondență este improbabilă.

Data mining este o unealtă foarte puternică, folosită în cele mai variate domenii. Iată câteva exemple:

Piața țintă. Obiectivul este acela de a folosi *data mining* pe baza rezultatelor unei campanii de direct-mail din trecut pentru a se identifica respondenții cei mai promițători, combinând date demografice și geografice culese la acea dată. Avantajele trebuie să fie o mai bună rată a respondenților și costuri mai scăzute ale noii campanii.

Grupul financiar Fleet a investit 38 de milioane de dolari în depozite de date pentru a-și înnoi infrastructura privind clienții.

Data mining a fost folosit pentru a prevedea probabilitatea de răspuns în ceea ce privește interesul pentru un credit ipotecar al 20.000 de clienți dintr-o bază de date de 15 milioane, a-i găsi pe cei profitabili și a-i depista pe cei neprofitabili chiar dacă ar răspunde favorabil.

Depistarea clienților ce au tendința de a renunța la serviciile firmei. Obiectivul este de a preveni atât pierderea clienților existenți cât și atragerea de clienți predispuși la a renunța ușor la serviciile firmei. Soluția *data mining* este identificarea pe baza unor caracteristici comune a clienților pe care să renunțe, folosind rețele neuronale și analize de serii cronologice. France Telecom a implementat în acest sens un Customer Profiling System (CPS), având ca rezultat detectarea rapidă a clienților cu tendința de renunțare prin compararea anumitor caracteristici ale acestora cu caracteristici ale celor care renunțaseră deja.

Detectarea fraudelor. Fraudele măresc costurile sau reduc veniturile. Folosind regresii și rețele neuronale pentru a determina caracteristicile esențiale ale cazurilor de fraudă pentru a le preveni pe viitor, se pot obține importante creșteri ale profitului, evitând clienții indezirabili. Automobile

Insurance Bureau of Massachusetts, o companie de asigurări auto, a folosit rapoarte vechi ale experților în legătură cu fraudele depistate. Mai multe caracteristici (peste 60), cum sunt tipul accidentului, tipul

final, verificând corectitudinea modelului generat prin testarea setului de date existent sau nou. Majoritatea timpurilor, în aplicațiile economice, scopul acestui algoritm este de a găsi metode pentru prognoza evenimentelor și rezultatelor viitoare pe baza datelor existente pentru a ajuta managerii să ia decizii repede și corect.

În alte situații, *data mining* poate fi folosită pentru a verifica dacă există o corelație ascunsă între datele de intrare și rezultate, sau dacă o asemenea corespondență este improbabilă.

Data mining este o unealtă foarte puternică, folosită în cele mai variate domenii. Iată câteva exemple:

Target market. Obiectivul este de a folosi *data mining* pe baza rezultatelor unei campanii de direct-mail din trecut pentru a se identifica respondenții cei mai promițători, combinând date demografice și geografice culese la acea dată. Avantajele trebuie să fie o mai bună rată a respondenților și costuri mai scăzute ale noii campanii.

Fleet Financial Group has invested 38 million dollars in data warehouses in order to upgrade infrastructure to customers.

Data mining was used to predict the likelihood of response in terms of a mortgage interest in the 20,000 customers from a database of 15 million you find those profitable and unprofitable even detect those that would welcome.

Finding customers who tend to drop the company. The objective is to prevent both loss of existing customers and attracting customers likely to abandon the company's services easier. *Data mining* solution is based on identifying common characteristics of customers about to abandon using neural networks and time series analysis. France Telecom has implemented a this Customer Profiling System (CPS), resulting in early detection of customers tend to abandon certain of their characteristics by comparing characteristics of those who already waived.

Fraud detection. Frauds increase costs or reduce revenues. Using regression and neural network to determine the essential characteristics of cases of fraud to prevent them in the future, to obtain significant increases in profits, while avoiding undesirable customers Automobile Insurance Bureau of Massachusetts, auto insurance company, used the old reports of experts in fraud detected. More features (over 60), such as accident type, the applied treatment, severity, were coded in a database.

Using specific *data mining* methods have been found common features in cases of fraud.

Risk analysis. The risk of loans to customers with the potential to become bad payers can be considerably reduced building separation functions customers based on certain characteristics.

Recommendation systems. Visitors and customers a virtual store on the Internet, for example

tratamentului aplicat, gravitate, au fost codificate într-o bază de date.

Folosind metode specifice de *data mining* au fost găsite caracteristici comune cazurilor de fraudă.

Analiza riscului. Riscul de a acorda credite unor clienți cu potențial de a deveni rău platnici poate fi diminuat considerabil construind funcții de separare a clienților pe baza anumitor caracteristici.

Sisteme de recomandare. Vizitatorii și clienții magazinelor virtuale pe Internet, de exemplu *amazon.com*, evaluează produsele prezentate. Informațiile astfel obținute sunt folosite pentru a recomanda produsele către alți vizitatori. Folosind tehnica numită „filtrare colaborativă”, companiile și-au crescut veniturile prin *cross-selling* și *up-selling*.

Un studiu online efectuat de site-ul de specialitate *KDnuggets.com* în luna august 2004 privind domeniile de utilizare a *data mining* a relevat următoarele: industria bancară este lider cu 13%, urmată de marketing direct, detecția fraudelor și cercetarea științifică cu câte 9%; alte domenii sunt biotehnologie cu 8%, asigurări și medicină cu 7% fiecare, comerț electronic și telecomunicații cu 6% fiecare, investiții financiare, manufactură, vânzare cu amănuntul și securitate cu 4% fiecare. Un alt studiu al aceluiași site, efectuat în luna septembrie 2004, promovează algoritmi ce produc arbori de decizie pe primul loc între categoriile de algoritmi sugerate.

Câteva pachete software comerciale folosite în *data mining* sunt: Oracle9i Data Mining pentru Oracle9i Database Enterprise Edition, Oracle Data Mining Suite, Teradata Warehouse Mining, SAS Enterprise Miner, Crystal Analysis and Decisions, Clementine, Smart Discovery, Monarch, Statistica, InfoBase, PolyAnalyst.

Câteva aplicații software gratuite, destinate mediului de cercetare și educație, sunt: IBM Intelligent Miner, WEKA, Tanagra, AdaM, YALE. Alte produse software pentru *data mining*, grupate pe categorii, pot fi găsite online pe site-ul *www.KDnuggets.com*

Aceast articol și-a propus ca obiectiv prezentarea unora dintre cele mai importante tehnici *data mining* a căror utilizare managementul relațiilor cu clienții a devenit și va fi crucială pe parcursul ultimilor ani.

Piețele actuale sunt supuse unui rapid proces de globalizare, caracteristicile competitive ale produselor și serviciilor sunt aproape identice, iar prezenta pe piață a ofertanților este masivă. Datorită dimensiunii și complexității acestor piețe, marketingul de masă a devenit tot mai scump, deci neprofitabil, fiind înlocuit cu *marketingul direct*, bazat pe selectarea grupurilor țintă de clienți și stabilirea de interacțiuni individualizate cu aceștia pe multiple canale de comunicare. Noul model de relaționare cu consumatorii potențiali presupune în schimb tehnici complexe de segmentare a piețelor, stabilirea profilului

www.amazon.com evaluate the products submitted. Such information is used to recommend products to other visitors. Using a technique called "collaborative filtering", the companies increased revenues through *cross-selling and up-selling*.

An online survey conducted by specialized *KDnuggets.com* site in August 2004 on the uses of *data mining* has revealed the following: the banking industry is leading by 13%, followed by direct marketing, fraud detection and scientific research by 9%, other areas are 8% biotechnology, medical insurance and 7% each, electronic commerce and telecommunications 6% each, investment, manufacturing, retail and security with 4% each. Another study by the same site, conducted in September 2004, promotes decision tree algorithms to produce the first among the categories of algorithms suggested.

Several commercial software packages are used in *data mining*: Oracle9i Data Mining for Oracle9i Database Enterprise Edition, Oracle Data Mining Suite, Mining Teradata Warehouse, SAS Enterprise Miner, Crystal Analysis and Decisions, Clementine, Smart Discovery, Monarch, Statistics, InfoBase, PolyAnalyst.

Some free software, for environmental research and education, are: IBM Intelligent Miner, WEKA, Tanagra, AdaM, YALE. Other *data mining* software products are grouped by category can be found online on the website *www.KDnuggets.com*.

This article has proposed that the objective of providing some of the most important *data mining* techniques whose use of customer relationship management will become crucial in recent years.

Current markets are subject to rapidly globalizing, competitive features of products and services are almost identical, and this is a massive market of bidders. Because of the size and complexity of these markets, mass marketing has become increasingly expensive, so unprofitable and was replaced with *direct marketing*, based on selecting target groups of clients and establishing individualized interactions with them on multiple channels. The new model involves networking with potential customers instead of complex techniques of market segmentation, profiling (shaping behavior) and inducing customers to attract or maintain persuasive strategies (loyalty), but also to win back those who migrate to other bidders.

The result was the company's strategic repositioning, the product-centric orientation which quickly turned into a customer-centric. To implement new strategies, companies have increasingly seen more obliged to use communication and information technologies (ICT) and information processing methods designed to abstract the relevant knowledge available databases and convert them into profitable

(modelarea comportamentului) clienților și inducerea de strategii persuasive pentru atragerea sau menținerea (fidelizarea) lor, dar și pentru recâștigarea celor ce migrează spre alți ofertanți.

Rezultatul a fost re poziționarea strategică a companiilor, a caror orientare produs-centrică s-a transformat rapid într-una client-centrică. Pentru a pune în practică noile strategii, firmele s-au vazut din ce în ce mai mult obligate să apeleze la tehnologiile comunicării și informației (ICT) și metodele de procesare a informației menite să abstraga cunoștințele relevante din bazele de date de care dispun și să le convertească în decizii profitabile.

Managementul relațiilor cu clienții (CRM – Customer Relationship Management) are ca obiect elaborarea de strategii pentru atragerea de noi clienți, menținerea celor existenți și recâștigarea celor care au migrat către un alt ofertant. La nivel operational, MRC include toate activitățile ce privesc *contactul direct cu consumatorul*.

La nivel analitic, MRC furnizează metodele pentru analiza caracteristicilor comportamentale ale clienților, prin analiza datelor obținute din sistemele de procesare a tranzacțiilor. Pe baza cunoștințelor astfel induse se stabilesc apoi strategiile de urmat în cadrul activităților operaționale.

Managementul relațiilor cu clienții are 3 obiective majore:

- *Segmentarea pieței*, ce descrie procesul de împărțire a consumatorilor în grupe cât mai omogene intern, pe baza similarităților manifestate (obiceiuri, gusturi, afinități, etc.). În schimb, grupele trebuie să fie cât mai eterogene între ele. Aceasta permite firmei să trateze personalizat diversele segmente de clienți și să se concentreze prioritar asupra grupurilor țintă ce corespund anumitor criterii de profitabilitate.

- *Stabilirea profilului consumatorului* presupune modelarea comportamentului consumatorilor în funcție de o paletă largă de atribute: geografice; culturale și etnice; condiții economice, venit și putere de cumpărare; frecvență de cumpărare, frecvența plângerilor și reclamațiilor, preferințele și gradul lor de satisfacere; vârsta; valorile, atitudinile și credințele; ciclul de viață; educația, nivelul de cultura; stilul de viață; canalele media utilizate; metoda de recrutare la care a răspuns clientul.

- *Poziționarea produsului* în preferințele (intențiile de cumpărare) ale potențialilor clienți este un instrument de marketing centrat pe identificarea celor mai atractive trăsături ale unui produs, astfel încât să maximizeze tentația cumpărătorului de a-l achiziționa.

Ambele categorii de metode Data Mining, atât cele descriptive (clustering), cât și cele predictive, sunt necesare pentru atingerea obiectivelor de mai sus.

Variabilele ce definesc profilul consumatorilor servesc pentru a determina măsurile de

decisions.

Customer Relationship Management (CRM) is to develop strategies to attract new customers, maintaining and restoring existing ones who have migrated to another bidder. At the operational level, the CRM includes all activities relating to *direct contact with consumers*.

At the analytical level, the CRM provides methods for analyzing behavioral patterns of customers, by analyzing data from transaction processing systems. Such knowledge to be induced and then determine the strategies followed in operational activities.

Customer relationship management has three major objectives:

1) *Market segmentation*, which describes the division of consumer groups as internally homogeneous, based on similarities manifested (habits, tastes, affinities etc.). Instead, groups should be more heterogeneous among themselves. This allows the company to treat various personalized customer segments and focus on priority target groups that match certain criteria of profitability;

2) *Setting consumer profiling* involves modeling consumer behavior based on a wide range of attributes: geographical, cultural and ethnic, economic conditions, income and purchasing power, frequency of purchase, frequency of complaints and grievances, preferences and their degree of satisfaction, age, values, attitudes and beliefs, life cycle, education, level of culture, lifestyle, media used, method of recruitment to that customer response;

3) *Product positioning* preferences (purchase intentions) of potential customers is a marketing tool focused on identifying the most attractive features of a product, the temptation to maximize the buyer's purchase.

Both categories of data mining methods both descriptive (clustering), and the predictive, are necessary to achieve the above objectives.

The variables that define customer profiles used to determine the degree of similarity/dissimilarity compared with segments that are built. In addition to the clustering role they play and the role of predictors, depending on which induce decision rules associated with marketing strategies. Rules then help the insertion of conclusions relative to a decision variable.

To identify segments of associative methods can be used, such as Learning Vector Quantization, or other methods combined: Conjoint Analysis and Descriptive Clustering. Regression methods are most appropriate when we want to understand consumer behavior in order to buy custom binding to certain predictors. Among the methods in this class that can be used are: Clusterwise Regression, Simulated

similaritate / disimilaritate în raport cu care se construiesc segmentele. În afara rolului jucat în clusterizare, ele joacă și rolul de predictor, în funcție de care se induc regulile de decizie asociate strategiilor de marketing. Regulile ajută apoi la inferarea de concluzii relative la o variabilă de decizie.

Pentru identificarea segmentelor se pot folosi metode asociative, precum Learning Vector Quantization, sau alte metode combinate: Conjoint Analysis și Descriptive Clustering. Metodele regresive sunt cele mai potrivite atunci când dorim să înțelegem comportamentul consumatorului, în scopul legării obiceiului de a cumpăra de anumiți predictor. Printre metodele din această clasă ce pot fi utilizate sunt: Clusterwise Regression, Simulated Annealing, etc.

Un exemplu de aplicare a metodelor bazate pe descoperirea regulilor de asociere sau pe identificarea secvențelor de episoade temporale este furnizarea **analiza coșului pietei**. Fiecare regulă de asociere are atașate două măsuri, prima numită suport și notată cu s , a doua numită încredere (confidența) și notată cu c . Suportul indică frecvența unui pattern (cât de des se asociază anumite elemente).

Atunci când din totalul tranzacțiilor asocierea apare în $s\%$ din cazuri, regula se scrie: Dacă X și Y , atunci Z cu suportul s . Suportul se calculează prin:

$$s(A \geq B) = P(A \cup B)$$

(1)

Confidența c desemnează puterea unei asocieri (cât de mult un element depinde de altul).

De exemplu: Dacă produsele X și Y sunt în coș, atunci produsul Z este de asemenea în coș în $c\%$ din cazuri. Avem: $c(A \geq B) = P(A \cup B) / P(A)$. Pe de altă parte, în cazul seriilor de timp pot apărea secvențe de episoade cu o anumită succesiune, a căror identificare poate sugera o secvență paralelă de decizii.

O versiune specializată a tehnicilor Data Mining sunt cele ce se referă la Web Mining.

Ele descriu procesul de descoperire a cunoștințelor prin analiza informațiilor din World Wide Web. Descoperirea se poate referi fie la conținut, fie la utilizare.

Tehnicile Web Mining au devenit esențiale în managementul *electronic* al relațiilor cu clienții. Dintre obiectivele Web Mining enumerăm: descoperirea regulilor de asociere pentru atragerea clienților; descoperirea episoadelor secvențiale ce ajută la menținerea clienților; inducerea regulilor de clasificare și descoperirea clusterelor pentru vânzări încrucișate. Aplicațiile Web Mining pot colecta date precum: protocoale http, Cookies, fișiere log ale serverelor, date de interogare (query data), numărul vizualizărilor de pagină, al vizitelor, al accesării reclamelor, timpii de vizualizare, etc. Un log de acces al unui server Web conține o istorie completă a fișierelor accesate de clienți. În intrarea unui log găsim adresa IP, ID-ul utilizatorului, timpul de acces și URL-ul.

Annealing etc.

Un exemplu de aplicare a metodelor bazate pe descoperirea regulilor de asociere sau pe identificarea secvențelor de episoade temporale este furnizarea **market basket analysis**. Fiecare regulă de asociere are atașate două măsuri, prima numită suport și notată cu s , a doua numită încredere (confidența) și notată cu c . Suportul indică frecvența unui pattern (cât de des se asociază anumite elemente).

Atunci când din totalul tranzacțiilor asocierea apare în $s\%$ din cazuri, regula se scrie: Dacă X și Y , atunci Z cu suportul s . Suportul se calculează prin:

$$s(A \geq B) = P(A \cup B) \tag{1}$$

Confidența c desemnează puterea unei asocieri (cât de mult un element depinde de altul).

De exemplu: Dacă produsele X și Y sunt în coș, atunci produsul Z este de asemenea în coș în $c\%$ din cazuri. Avem: $c(A \geq B) = P(A \cup B) / P(A)$. Pe de altă parte, în cazul seriilor de timp pot apărea secvențe de episoade cu o anumită succesiune, a căror identificare poate sugera o secvență paralelă de decizii.

O versiune specializată a tehnicilor Data Mining sunt cele ce se referă la Web Mining.

Ele descriu procesul de descoperire a cunoștințelor prin analiza informațiilor din World Wide Web. Descoperirea se poate referi fie la conținut, fie la utilizare.

Tehnicile Web Mining au devenit esențiale în managementul *electronic* al relațiilor cu clienții. Dintre obiectivele Web Mining enumerăm: descoperirea regulilor de asociere pentru atragerea clienților; descoperirea episoadelor secvențiale ce ajută la menținerea clienților; inducerea regulilor de clasificare și descoperirea clusterelor pentru vânzări încrucișate. Aplicațiile Web Mining pot colecta date precum: protocoale http, Cookies, fișiere log ale serverelor, date de interogare (query data), numărul vizualizărilor de pagină, al vizitelor, al accesării reclamelor, timpii de vizualizare, etc. Un log de acces al unui server Web conține o istorie completă a fișierelor accesate de clienți. În intrarea unui log găsim adresa IP, ID-ul utilizatorului, timpul de acces și URL-ul.

In e-Commerce, câmpurile pot conține chei tipice produsului consumator, locație, dată și sesiune, și unele informații statistice (cantitate, preț total etc.). Descoperirea regulilor de asociere poate ajuta la dezvoltarea strategiilor de marketing efective, precum și la indicarea celui mai bun mod de organizare a spațiului Web. Secvențele de episoade de descoperire a logurilor de acces ale serverelor Web permit firmelor să descoperească anumite regularități în modul de succesiune al vizitelor la utilizatori și să le ajute în determinarea grupurilor țintă adresate prin publicitatea adecvată. Astfel

În e-Comerț, câmpurile tipice pot conține cheile consumatorului, produsului, locației, datei și sesiunii, precum și anumite informații statistice (cantitatea, prețul total, etc.). Descoperirea regulilor de asociere poate ajuta în dezvoltarea unor strategii de marketing efective, precum și în indicarea celui mai bun mod de organizare a spațiului Web al firmelor. Descoperirea secvențelor de episoade în log-urile de acces ale serverelor Web permite firmelor să descopere anumite regularități în modul de succedare a vizitelor utilizatorilor și le ajută în stabilirea grupurilor țintă cărora li se adresează acțiunile de publicitate. Cât privește metodele de clasificare, acestea pot fi utilizate pentru generarea profilului elementelor ce aparțin unui grup țintă particular, potrivit atributelor acestora.

Profilul poate fi apoi utilizat pentru a clasifica noi elemente ce intră în baza de date. În Web Mining, profilul este generat pentru clienții ce accesează fișiere particulare ale serverului și se bazează pe informația demografică disponibilă despre acei clienți.

Concluzii

Considerăm că firmele de pe piața românească, mai ales cele autohtone, trebuie să se adapteze rapid tendinței globale de focalizare a strategiilor de afaceri pe managementul relațiilor cu clienții, bazat pe utilizarea tehnicilor data mining, pentru a face față competiției firmelor multinaționale, acestea aplicând cu succes principiile acestei abordări. În numeroase firme din România se creează confuzii privind acest concept. Pentru unele, managementul relațiilor cu clienții înseamnă doar implementarea unei programe de loialitate, pentru altele crearea unei baze de date cu informații despre clienți cu ajutorul cărora se poate realiza o segmentare mai fină a pieței, însă puține au implementat sisteme de relații cu clienții integrate și au o idee clară despre cum trebuie tehnologii informaționale în managementul relațiilor cu clienții.

BIBLIOGRAFIE

Allard C. – *[Management de la Valeur Client, Ed. Dunod, Paris, 2003.]*

Elena Joița - *[Data mining. Curs universitar, Editura Universității Titu Maiorescu, București, 2007.]*

Georgescu, V. (2001) – *[Fuzzy Control Applied to Economic Stabilization Policies, Studies in Informatics and Control, Vol. 10, Number 1 / March 2001, pp. 37-60, ISSN 1220-1766.]*

Georgescu, V. (2002) – *[Capturing and Tuning Non-linear Characteristics of Economic Stabilization Systems by Fuzzy Control Techniques”, Computational Economics, Vol. 19, No. 3, pp. 247-271, Kluwer Academic Publishers, Holland, June 2002, ISSN 0927-7099.]*

methods of classification, they can be used to generate the profile elements that belong to a particular target group, according to their attributes

Profile can then be used to classify new elements enter into the database. In Web Mining, the profile is generated for clients accessing the server's private files and based on available demographic information about those customers.

Conclusions

We believe that companies on the Romanian market, especially domestic ones, must adapt quickly to the global trend to focus on business strategies, customer relationship management, based on data mining techniques for multinational firms to compete, applying them to principles of this approach successful. In many companies in Romania are confusing the concept. For some, customer relationship management is just implementing a loyalty program for others to create a database of customer information by which we can achieve a finer segmentation of the market, few systems have implemented integrated customer have a clear idea of how information technologies in customer relationship management.

REFERENCES

Allard, C.- *[Management de la Valeur Client, Dunod Publishing, Paris, 2003].*

Joița, E. – *[Data mining. University Lecture, University “Titu Maiorescu”, Bucharest, 2007.]*

Georgescu, V. – *[Fuzzy Control Applied to Economic Stabilization Policies”, Studies in Informatics and Control, Vol. 10, Number 1 / March 2001, pp. 37-60, ISSN 1220-1766.]*

Georgescu, V. – *[Capturing and Tuning Non-linear Characteristics of Economic Stabilization*

Jiawei Han, Micheline Kamber, - *[Data Mining, Second Edition: Concepts and Techniques, San Francisco, Morgan Kaufmann, 2006.]*

Kotler Ph. - *[Managementul marketingului, Editura Teora, București, 1999.]*

Systems by Fuzzy Control Techniques”, Computational Economics, Vol. 19, No. 3, pp. 247-271, Kluwer Academic Publishers, Holland, June 2002, ISSN 0927-7099.]

Han, J, Kamber, M. - *[Data Mining, Second Edition: Concepts and Techniques, San Francisco, Morgan Kaufmann, 2006.]*

Kotler, Ph.- *[Marketing Management, Teora Publishing House, Bucharest, 1999.]*