

Mașini cu vectori suport nuanțate – o nouă abordare în clasificarea datelor

Gheorghe RADU, Ștefan-Gheorghe PENTIUC

Abstract—Support vector machines (SVMs) have proven to be a powerful tool for classification and regression. However, there still remain some problems to be solved. One of them is that SVMs are very sensitive to outliers because of so-called overfitting problem. In this paper a new fuzzy support vector machine, based on a fuzzy distance, is proposed to deal with the problem.

Index terms—Fuzzy distance, generalized Fuzzy n-Means, Support Vector Machines.

I. INTRODUCERE

În această lucrare vom prezenta un model original de mașini nuanțate cu vectori suport. Spre deosebire de alte modele similare (vezi, de exemplu, [7]), abordarea de față se bazează pe distanța locală în raport cu o mulțime nuanțată, definită de Gerla și Volpe [5].

În secțiunea II sunt prezentate sumar idei și mecanisme ale SVM-urilor „clasice” (ce pot fi urmărite pe larg în [2], [9]), iar în secțiunea III este prezentată o mașină nuanțată cu vectori suport și problema de optimizare asociată cazului în care datele de instruire nu sunt liniar separabile. În continuare sunt trase câteva concluzii din analiza modelului teoretic prezentat.

II. MAȘINI CU VECTORI SUPORT (SVM)

A. Instruirea SVM: un punct de vedere geometric

Să considerăm cazul unei probleme de clasificare binară în care tipul de învățare este instruirea (antrenarea) supervizată. Astfel, fiind dată o mulțime de funcții:

$$\{f_w \mid w \in W\}, f_w : \mathcal{X}^n \rightarrow \{-1, +1\}$$

și o mulțime de exemple de instruire:

$$\{(x_i, y_i)\}_{i=1,2,\dots,m}, \text{ unde fiecare } x_i \in R^n \text{ reprezintă un}$$

vector de intrare (sau formă) și fiecare $y_i \in \{-1, 1\}$ reprezintă ieșirea corespunzătoare (sau eticheta), se cere a

învăța funcția optimă f_w care minimizează eroarea, adică diferența dintre ieșirea dorită și cea obținută de mașina de învățare pentru un vector de intrare. Să presupunem că avem o

mașină a cărei sarcină este să învețe maparea $x_i \rightarrow y_i$.

Gheorghe RADU is with “Henri Coandă” Air Force Academy, #160, M. Viteazul street, 500183 Brașov, gh.radu@gmail.com. He is also a PhD student at “Ștefan cel Mare” University of Suceava Ștefan-Gheorghe PENTIUC, PhD, is with “Ștefan cel Mare” University of Suceava, #13, Universității street, 720229 Suceava, pentiuc@eed.usv.ro

De fapt, mașina este definită de o mulțime de mapări posibile $x \rightarrow f(x, w)$, unde funcția f depinde de un parametru w . Se presupune că mașina este deterministă, adică: pentru un vector de intrare x fixat și pentru un parametru w ales, funcția va avea mereu același rezultat. O alegere particulară a lui w va genera ceea ce se numește o mașină instruită (antrenată), cu care se trece la etapa de testare.

Fiind dată o mulțime de date de antrenare, să presupunem mai întâi că cele două submulțimi de vectori de intrare corespunzând etichetelor $y_i = +1$, respectiv $y_i = -1$, sunt liniar separabile. Vectorii de intrare „pozitivi” și „negativi” vor putea fi separați de un hiperplan.

Ecuția hiperplanului de separare este:

$$\langle w, x \rangle - b = 0, \quad (1)$$

unde $w \in R^n$ este normala la hiperplan, $b \in R$ și $\frac{|b|}{\|w\|}$ este

distanța de la origine la hiperplan. Mai simplu, w este orientarea hiperplanului iar b este localizarea acestuia.

Ilustrarea acestei idei este dată în Figura 1.




Fig. 1. Vectorii de intrare “pozitivi” și “negativi” și hiperplanul de separare între cele două mulțimi.

Conform [1], două submulțimi de vectori de dimensiune n sunt liniar separabile dacă și numai dacă există $w \in R^n$ și $b \in R$ astfel încât:

$$\begin{cases} \langle w, x_i \rangle - b \geq +1, y_i = +1 \\ \langle w, x_i \rangle - b \leq -1, y_i = -1 \end{cases}, \text{ pentru } i = 1, 2, \dots, m \quad (2)$$

Punctele (x_i, y_i) pentru care se realizează *egalitățile* în relațiile (1.2) se numesc **vectorii suport**.

Acestea sunt punctele cele mai apropiate de suprafața de decizie. Ștergerea acestora va modifica soluția găsită.




Fig. 2. Hiperplanul de separare și hiperplanele suport pentru mulțimi separabile. Vectorii suport sunt încercuți

Ilustrarea acestei idei este făcută în Figura 2. Hiperplanul de separare H_0 este cel care trece prin mijlocul distanței dintre cele două hiperplane paralele H_1 și H_2 ce conțin vectorii suport pentru cele două clase.

Întrebarea este cum putem determina hiperplanul, adică w și b , care realizează separarea optimă, adică acel hiperplan care stabilește cea mai mare lățime a benzii de separare (numită *margine*).

Inegalitățile (2) se pot reuni sub forma:

$$y_i (\langle w, x_i \rangle - b) - 1 \geq 0, \text{ pentru toți } i = 1, 2, \dots, m \quad (3)$$

Distanța de la un punct oarecare z la hiperplanul de separare w este dată de:

$$\frac{|\langle w, z \rangle - b|}{\|w\|}$$

Rezultă că distanța de la vectorii suport z_i la hiperplanul de separare este:

$$\frac{|\langle w, z_i \rangle - b|}{\|w\|} = \frac{1}{\|w\|} \quad (4)$$

pentru toți indicii i pentru care $|\langle w, z_i \rangle - b| = 1$.

$$\text{Așadar, marginea este (vezi [11]) } \frac{2}{\|w\|} \quad (5)$$

B. SVM liniare. Cazul neseparabil

Fiind dată o mulțime de date de instruire care nu este liniar separabilă, este evident că nu putem construi un hiperplan de separare fără unele erori de clasificare. Totuși, construirea unui hiperplan optim care minimizează vectorii clasificați eronat poate fi de interes.

Discuția din paragraful precedent poate fi extinsă pentru a trata noua situație prin relaxarea restricțiilor din (2). Aceasta se poate face prin introducerea unor variabile pozitive, numite *variabile de relaxare* (slack variables, [3]; *slack= loose, relaxed*).

Introducerea acestor noi variabile „permite” unor puncte din datele de instruire o deviere de la hiperplanul lor suport, față

de condiția ideală de separabilitate, de $-\frac{\xi_i}{\|w\|}$.

Restricțiile (2) devin:

$$y_i (\langle w, x_i \rangle - b) \geq 1 - \xi_i, i = 1, 2, \dots, m, \quad (6)$$

unde $\xi_i \geq 0$.

Astfel, pentru ca un punct din datele de instruire să reprezinte o eroare de clasificare, variabila sa de relaxare ξ_i trebuie să fie mai mare ca 1.

Punctele (x_i, y_i) pentru care în (6) avem egalități sunt vectorii suport.

În Figura 3 este reprezentată o separare liniară pentru date de instruire neseparabile.




Fig. 3. Hiperplanul de separare și hiperplanele support pentru mulțimi de date de instruire neseparabile. Vectorii suport sunt încercuți. Este marcat și punctul incorect clasificat.

Pentru a obține un hiperplan optimal, simultan cu (6) trebuie minimizată suma clasificarilor eronate:

$$\min C \sum_{i=1}^m \xi_i,$$

unde C este un parametru real pozitiv ales de utilizator. O valoare mai mare a lui C reprezintă o penalizare mai mare a erorilor. Astfel, problema de optimizare ia următoarea formă:

Fiind dată mulțimea de exemple de instruire

$$\{(x_i, y_i)\}_{i=1,2,\dots,m},$$

să se determine valorile **optime** ale lui **w** și **b** care **minimizează** funcția

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i, C > 0$$

cu **restricțiile**:

$$\begin{cases} y_i (\langle w, x_i \rangle - b) \geq 1 - \xi_i, i = 1, 2, \dots, m. \\ \xi_i \geq 0 \end{cases}$$

Se poate vedea că această abordare satisface principiul minimizării riscului structural: dimensiunea VC (Vapnik-Cervonenkis) să fie minimizată și datele de instruire să fie separate cu cât mai puține excepții posibil, cu satisfacerea condițiilor (5) și (6).

Considerăm acum problema duală a SVM (a se vedea [6]) pentru acest caz; Pentru această problemă, lagrangeianul are următoarea expresie:

$$L(w, b, \xi, \alpha, \mu) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i - \sum_{i=1}^m \alpha_i [y_i (\langle w, x_i \rangle - b) - 1 + \xi_i] - \sum_{i=1}^m \mu_i \xi_i$$

unde variabilele α_i și μ_i sunt multiplicatorii lui Lagrange.

Aplicând condițiile KKT și explicitând termen cu termen, lagrangianul devine:

$$L(w, b, \xi, \alpha, \mu) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle + C \sum_{i=1}^m \xi_i - \sum_{i=1}^m \alpha_i \xi_i - \sum_{i=1}^m \mu_i \xi_i$$

În consecință, obținem următoarea problemă duală:

Fiind dată mulțimea de exemple de instruire

$$\{(x_i, y_i)\}_{i=1,2,\dots,m},$$

să se determine **multiplicatorii lui Lagrange** $\{\alpha_i\}_{i=1,2,\dots,m}$ care **maximizează** funcția obiectiv

$$Q(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle$$

$$\text{cu restricțiile: } \begin{cases} \sum_{i=1}^m \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C \end{cases}, i = 1, 2, \dots, m, C > 0.$$

Valoarea optimă w^* este calculată astfel:

$$w^* = \sum_{i=1}^m \alpha_i^* y_i x_i.$$

În ceea ce privește calculul lui b , acesta se poate face după cum urmează ([6]):

Dacă vom considera toate valorile $\alpha_i \neq 0$ care satisfac și

condiția $\alpha_i < C$, atunci se obține aceeași ecuație ca și în cazul separabil:

$$y_i (\langle w, x_i \rangle - b) - 1 = 0$$

$$\Rightarrow b = \sum_{j=1}^m \alpha_j y_j \langle x_j, x_i \rangle - y_i.$$

Iarăși, este mai bine să luăm pentru b media valorilor rezultate din toate aceste ecuații.

Acele puncte pentru care $0 < \alpha_i < C$ sunt **vectorii suport**.

III. MAȘINI CU VECTORI SUPT NUAŢATE (FSVM)

A. „Fuzzificarea” datelor de instruire

Tratarea în mod egal a datelor de instruire poate conduce la fenomenul numit *overfitting* (suprapotrivire neadecvată). Apare, în mod natural, ideea de a asigna fiecărui punct un grad de apartenență corespunzător importanței sale relativ la clasa din care face parte. Din moment ce fiecărui punct x_i i s-a asignat un grad de apartenență, mulțimea datelor de instruire devine o *mulțime nuanțată*.

În felul acesta, mașinile cu vectori suport, SVM, sunt transformate în mașini *nuanțate* cu vectori suport, FSVM (Fuzzy Support Vector Machines).

Întrucât FSVM, ca și SVM, au drept obiectiv maximizarea marginii de separare și minimizarea erorilor de clasificare, în vederea atingerii unei înalte abilități de generalizare, propunem două abordări diferite de fuzzificare a datelor de instruire și de formulare, în consecință, a problemei de optimizare a FSVM:

1. Margine clară (mulțime clasică), dar cu apartenența difuză a punctelor la mulțimea de instruire.
2. Margine nuanțată: regiunea de separare (marginea) M este o mulțime nuanțată peste X , notația $M(x)$ reprezentând gradul de apartenență al lui x la regiunea de separare.

În continuare, vom prezenta prima abordare. Reamintim că obiectivele principale ale acestei abordări constau în detectarea anomaliilor și prelucrarea datelor de instruire afectate de zgomot, luând în considerare și informații despre calitatea mulțimii de date de antrenare. Pentru atingerea acestor obiective, pot fi avute în vedere mai multe metode și tehnici prin care atribuim grade de apartenență/ importanță/ relevanță punctelor din mulțimea de date de instruire:

a) Utilizarea unui algoritm care să atribuie grade de apartenență pe baza importanței fiecărui punct în domeniul problemei. Pentru a păstra acea caracteristică unică (printre modelele de învățare) a SVM-urilor de a nu încorpora cunoștințe despre domeniul problemei, această metodă este puțin recomandată.

b) Utilizarea unei unelte *inteligente*, capabile să trateze diferențiat surse de date cu diferite grade de încredere. Rețeaua neuronală „Fuzzy ARTMAP cu factor de relevanță” (FAMR, a se vedea, de exemplu, [8]) ia în considerare

informații despre calitatea mulțimilor de date de antrenare, poate fi folosită pentru clasificare și este superioară modelelor concurente în prelucrarea datelor afectate de zgomot.

c) O metodă euristică originală, ce va fi prezentată în continuare.

Fie $X = \{x_1, x_2, \dots, x_m\}$ mulțimea vectorilor din datele de instruire. Considerăm că S este o mulțime nuanțată peste X , corespunzând la o clasă de puncte. Admitem că S conține două subclase care sunt descrise de partiția nuanțată $\{A_1, A_2\}$ a lui S , unde elementele lui A_1 sunt vectorii x_i pentru care $y = -1$ (punctele „negative”), iar elementele mulțimii A_2 sunt punctele „pozitive”; avem:

$$A_k : X \rightarrow [0,1], \quad k = 1, 2; \quad (7)$$

$$A_1(x_i) + A_2(x_i) = 1, \quad i = 1, 2, \dots, m.$$

Această structură poate fi obținută cu un algoritm de clasificare cu mulțimi nuanțate folosind, de exemplu, algoritmul *n-Medii Nuanțat Generalizat* (Generalized Fuzzy n-Means, GFNM). Pentru completitudinea prezentării, dăm mai jos acest algoritm ([4]):

Algoritmul *n – Medii Nuanțat Generalizat*

P1. Se inițializează o partiție nuanțată $P^1 = A_1, \dots, A_n$ a mulțimii nuanțate C . Se alege eroarea admisibilă *eps*. De exemplu, $eps = 10^{-5}$.

P2. Se calculează prototipul L^i al fiecărei clase A_i , folosind formula:

$$L^i = \frac{\sum_{j=1}^p (A_j(x^j))^2 x^j}{\sum_{j=1}^p A_j^2(x^j)}, \quad i = 1, \dots, n; \quad j = 1, \dots, p.$$

P3. Se actualizează partiția nuanțată P^1 calculând o nouă partiție P^2 ai cărei atomi se obțin cu formula:

$$A_i(x^j) = \frac{C(x^j)}{\sum_{k=1}^n \frac{d^2(x^j, L^k)}{d^2(x^j, L^i)}}, \quad i = 1, \dots, n; \quad j = 1, \dots, p.$$

P4. Dacă P^2 este suficient de aproape de P^1 , adică $\|Q^2 - Q^1\| < eps$,

unde Q^2 și Q^1 sunt matricile reprezentative ale partițiilor P^2 și P^1 , iar $\|Q\|$ este norma matricei Q , atunci STOP.

În caz contrar, se pune $P^1 := P^2$ și se merge la pasul P2.

Observații.

a) Dacă, în algoritmul de mai sus, se pune $C=X$, se obține algoritmul *n - Medii Nuanțat*.

b) Norma unei matrice Q se poate defini în mai multe feluri. Putem considera, de exemplu,

$$\|Q\| = \max_{i,j} |Q_{ij}|.$$

c) Pentru cazul nostru se iau: $C=S$, $S=X$, $n=2$, $p=m$, iar distanța care apare în formula de la pasul **P3** este, în conformitate cu [4,5], $d = d_C^*$.

Considerăm mulțimile (clasice) $\text{supp } A_1$, $\text{supp } A_2$, A_1^* și A_2^* , obținute prin defuzzificarea mulțimilor nuanțate A_1 , respectiv A_2 :

$$A_1^* = \{x / A_1(x) > 0,5\}; \quad (8)$$

$$A_2^* = \{x / A_2(x) > 0,5\};$$

În modelul de SVM propus, **definim** lărgimea benzii de separare nuanțate, *marginea D*, astfel:

$$D = \min_{x \in A_1^*} A_1(x) + \min_{x \in A_2^*} A_2(x) \quad (9a)$$

Prin urmare, analogul formulei (5) pentru modelul de SVM nuanțat este:

$$M = \frac{\min_{x \in A_1^*} A_1(x)}{\|w\|} + \frac{\min_{x \in A_2^*} A_2(x)}{\|w\|} = \frac{D}{\|w\|} \quad (9b)$$

Din definiția (9a) rezultă imediat:

$$\frac{1}{\|w\|} < \frac{D}{\|w\|} < \frac{2}{\|w\|} \quad (10)$$

și, prin urmare, cerința de maximizare a marginii conduce la următoarea problemă de optimizare: $\min \frac{\|w\|^2}{D}$.

Să notăm:

$$X^* = A_1^* \cup A_2^*; \quad (11)$$

$$r = \text{card}(X^*); \quad (12)$$

$$t_i = \begin{cases} A_1(x_i), & \text{dacă } y_i = -1 \\ A_2(x_i), & \text{dacă } y_i = +1 \end{cases} \quad i=1, 2, \dots, m. \quad (13)$$

Evident, $r \leq m$ și putem considera că, printr-o renumerotare a elementelor mulțimii X , primele r dintre acestea vor fi elementele mulțimii X^* .

Modelul bazat pe construcția de mai sus va fi numit *Fuzzy SVM* (FSVM).

Cu aceste construcții, putem trece la formularea problemei de optimizare a FSVM-urilor.

B. Problema de optimizare a FSVM

Ca și SVM-urile, FSVM-urile sunt construite să maximizeze marginea de separare și să minimizeze erorile de clasificare pentru a atinge o înaltă abilitate de generalizare.

Spre deosebire de SVM-uri, FSVM-urile fuzzifică termenul de penalizare (a punctelor eronat clasificate) cu scopul de a reduce efectul datelor mai puțin relevante (anomalii sau zgomote).

În acest caz, problema de optimizare cu restricții este definită astfel:

Fiind dată mulțimea de exemple de instruire

$$\{(x_i, y_i, t_i)\}_{i=1,2,\dots,m},$$

să se determine valorile optime ale lui w și b care minimizează funcția obiectiv

$$\Phi(w, \xi) = \frac{1}{D} \|w\|^2 + C \sum_{i=1}^m t_i \xi_i, \quad C > 0$$

cu restricțiile:

$$\begin{cases} y_i (\langle w, x_i \rangle - b) \geq 1 - \xi_i, & i = 1, 2, \dots, m. \\ \xi_i \geq 0 \end{cases}$$

Pentru această problemă, lagrangeianul are următoarea expresie:

$$L(w, b, \xi, \alpha, \mu, t) = \frac{1}{D} \|w\|^2 + C \sum_{i=1}^m t_i \xi_i - \sum_{i=1}^m \alpha_i [y_i (\langle w, x_i \rangle - b) - 1 + \xi_i] - \sum_{i=1}^m \mu_i \xi_i$$

unde variabilele α_i și μ_i sunt multiplicatorii lui Lagrange.

Aplicând condițiile Karush-Kuhn-Tucker-Lagrange (KKT), după explicitarea termen cu termen lagrangeianul devine:

$$L(w, b, \xi, \alpha, \mu, t) = \sum_{i=1}^m \alpha_i - \frac{D}{2} \left(1 - \frac{D}{2}\right) \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle + C \sum_{i=1}^m t_i \xi_i - \sum_{i=1}^m \alpha_i \xi_i - \sum_{i=1}^m \mu_i \xi_i.$$

Dezvoltând termen cu termen, se obține:

$$\begin{aligned} L(w, b, \xi, \alpha, \mu, t) &= \sum_{i=1}^m \alpha_i - \frac{D}{2} \left(1 - \frac{D}{2}\right) \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle + \sum_{i=1}^m (\alpha_i + \mu_i) \xi_i - \sum_{i=1}^m \alpha_i \xi_i \\ &= \sum_{i=1}^m \alpha_i - \frac{D}{2} \left(1 - \frac{D}{2}\right) \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle + \sum_{i=1}^m \alpha_i \xi_i + \sum_{i=1}^m \mu_i \xi_i - \sum_{i=1}^m \alpha_i \xi_i \\ &= \sum_{i=1}^m \alpha_i - \frac{D}{2} \left(1 - \frac{D}{2}\right) \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle. \end{aligned}$$

În consecință, obținem următoarea problemă duală:

Fiind dată mulțimea de exemple de instruire

$$\{(x_i, y_i, t_i)\}_{i=1,2,\dots,m},$$

să se determine multiplicatorii lui Lagrange $\{\alpha_i\}_{i=1,2,\dots,m}$

care maximizează funcția obiectiv

$$Q(\alpha) = \sum_{i=1}^m \alpha_i - \frac{D}{2} \left(1 - \frac{D}{2}\right) \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle$$

$$\text{cu restricțiile: } \begin{cases} \sum_{i=1}^m \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C t_i \end{cases}, \quad i = 1, 2, \dots, m, \quad C > 0.$$

A doua restricție este obținută din condiția ca $\mu_i \geq 0$, $i = 1, 2, \dots, m$.

Valoarea optimă w^* este calculată, din nou, astfel:

$$w^* = \sum_{i=1}^m \alpha_i^* y_i x_i.$$

În ceea ce privește calculul lui b , acesta se poate face după cum urmează:

Dacă vom considera toate valorile $\alpha_i \neq 0$ care satisfac și condiția $\alpha_i < C t_i$, atunci, din condițiile KKT $\Rightarrow \mu_i \neq 0$, $\xi_i = 0$.

În aceste condiții, se obține aceeași ecuație ca și în cazul neseparabil clasic:

$$y_i (\langle w, x_i \rangle - b) - 1 = 0$$

$$\Rightarrow b = \sum_{j=1}^m \alpha_j y_j \langle x_j, x_i \rangle - y_i,$$

pentru orice i pentru care $0 < \alpha_i < C t_i$.

Iarăși, este mai sigur să luăm pentru b media valorilor rezultate din toate aceste ecuații.

Acele puncte pentru care $0 < \alpha_i < C t_i$ sunt vectorii suport.

Observații

Este clar că singura diferență între SVM și FSVM apare la limitele superioare ale multiplicatorilor lui Lagrange α_i din problema duală. În cazul SVM-urilor, toți multiplicatorii sunt mărginiți superior de constanta C , în timp ce, în cazul FSVM, multiplicatorii lui Lagrange α_i au limite superioare variabile, depinzând de gradul de apartenență. Cu cât gradul de apartenență al unui punct este mai mic, cu atât mai îngustă va fi regiunea de separare determinată de hiperplanul ce trece prin α_i .

Putem înlocui pe M din (9b) cu următoarea definiție:

$$M = \frac{\min_{x \in \sup p A_1} A_1(x)}{\|w\|} + \frac{\min_{x \in \sup p A_2} A_2(x)}{\|w\|} = \frac{D}{\|w\|}. \quad (14)$$

În acest caz, inegalitatea (10) se înlocuiește cu:

$$\frac{0}{\|w\|} < \frac{D}{\|w\|} < \frac{2}{\|w\|}. \quad (15)$$

Înlocuirea lui m cu r , conform definiției (12), în problema de optimizare cu restricții (și în toate formulele din această secțiune) va conduce la o eliminare mult mai severă a anomaliilor și, în consecință, la o reducere considerabilă a dimensiunii problemei de programare pătratică.

I. CONCLUZII

În acest articol am prezentat un nou tip de clasificator instruibil nuanțat: mașini cu vectori suport *nuanțate*, FSVM – *Fuzzy Support Vector Machines*. Acest model tratează problema *suprapotrivirii (overfitting)*, care apare în mod special în clasificarea binară (cu două clase) a SVM-urilor „tradiționale” (cazul formelor liniar neseperabile). Se demonstrează reducerea suprapunerii neadecvate (*overfitting*) și, în mod corespunzător, a erorilor de clasificare.

Avantaje ale abordării propuse :

- se reduce numărul punctelor greșit clasificate; sunt neglijate acele puncte care sunt prea depărtate de „centrii” (prototipurile) claselor lor;
- se reduce semnificativ dimensiunea problemei de programare pătratică;
- se micșorează marginea (lărgimea benzii de separare), dar aceasta va fi definită de un număr mai mic de vectori suport, ceea ce va conduce la o ameliorare a performanțelor clasificatorului în faza de testare și, respectiv, în faza de lucru (clasificare).

REFERINȚE

- [1] R.A. Bosch, J.A. Smith, *Separating Hyperplanes and the Authorship of the Disputed Federalist Papers*, American Mathematical Monthly, Volume 105, Number 7, pp. 601-608, 1998
- [2] C.J.C. Burges, *A Tutorial on Support Vector Machines for Pattern Recognition*, Data Mining and Knowledge Discovery, 2, pp. 121-167, 1998
- [3] C. Cortes, V. Vapnik, *Support Vector Networks*, Machine Learning, 20, pp. 273-297, 1995
- [4] D. Dumitrescu, *Hierarchical Pattern Classification*, Fuzzy Sets and Systems, 28, pp. 145 – 162, 1988
- [5] G. Gerla, R. Volpe, *The Definition of Distance and Diameter in Fuzzy Set Theory*, Studia Univ. Babeș-Bolyai, Math., 3, pp. 21-26, 1986
- [6] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, New Jersey, 1999
- [7] H.-P. Huang, Y.-H. Liu, *Fuzzy Support Vector Machines for Pattern Recognition and Data Mining*, International Journal of Fuzzy Systems, Vol. 4, No. 3, pp. 826 – 835, September 2002
- [8] L. M. Sasu, *Computational Intelligence Techniques in Data Mining*, PhD Thesis, Transilvania University of Brașov, Brașov, 2006
- [9] R. Stoean, D. Dumitrescu, *Evolutionary Support Vector Machines*, Technical Report, Department of Computer Science, Faculty of Mathematics and Computer Science, “Babes-Bolyai” University, 2005
- [10] V. N. Vapnik, *The Nature of Statistical Learning Theory*, Springer Verlag, New York, 1995
- [11] A. Zaknich, *Neural Networks for Intelligent Signal Processing*, World Scientific Publishing, Singapore, 2003