

UOT 004.021

K.R. AYDA-ZADƏ, C.Z. HƏSƏNOV

AZƏRBAYCAN ƏLYAZMA HƏRFLƏRİNİN DAYAQ VEKTORLARI ÜSULU VASİTƏSİLƏ TANINMASININ TƏHLİLİ

Obrazları öyrənmə və tanıma üçün isifadə olunan yeni üsullardan biri, Dayaq Vektor Üsullarının (Support Vector Machine) xüsusiyyətləri və onun əlyazmaları tanımada tətbiqi göstərmişdir. Sistemin ilkin emal, əlamətlərin seçilməsi, öyrənmə və tanıma kimi mərhələləri hər biri ayrılıqda təhlil edilərək, tanımada oynadığı rolu göstərilmişdir. Məqalənin sonunda tanıma DVÜ-nin tətbiqi zamanı fikir verilməsi vacib olan məqamlar və təcrübələrdən alınmış nəticələr sadalınmışdır.

Açar sözlər: əlyazma, tanıma, əlamətlər, dayaq vektorları, SVM, support vector machine

1. Giriş. Obrazları tanımaq üçün müxtəlif riyazi modellərə əsaslanan və müxtəlif strukturlu tanıma sistemləri işlənmişdir. Yazıları tanıma, obrazları tanıma probleminin bir hissəsi olub, məsələnin qoyuluşu və həll üsullarının növlərinə görə kifayət qədər mürəkkəb hesab edilə bilər. Yazıların əlifba (latın, ərəb, kiril, ieroqlif və s.) və yazı tərzinə (çap, əllə yazılmış çap, əlyazma və s.) görə dəyişməsi məsələnin birmənalı həllinin tapılmasını müşkül edir. Bu məqsədlə hər bir əlifba və yazı tərzini üçün effektiv olacaq tanıma sistemləri yaradılmışdır ki, onun digər yazılar üçün eyni effekt verməsi heç də həmişə doğru deyil.

Əlyazma çap yazısından fərqli olaraq müxtəlif variasiyalarda və bitişik yazıldığı üçün tanıma məsələsini daha da mürəkkəbləşdirir. Burada yaranan problemləri həll etmək üçün bəzi yanaşmalar mətnlərin seqmentlənərək, yazı elementlərinə (simvollara) ayrılıb, ayrılıqda tanınması, digərləri isə yazını kəsilməz olaraq təhlil edərək tanımağı təklif edir [1, s.1028-1033; 2, s.563-579].

[3, s.63-67] işində təklif olunan Azərbaycan dilində latın əlifbası ilə yazılmış mətnləri tanıma sistemində yazılar 3-mərhələli seqmentləmə alqoritmi vasitəsilə simvollara ayrılaraq, neyron şəbəkə tərəfindən öyrədilir, tanıma zamanı isə ayrılmış simvollar neyron şəbəkələr sistemləri vasitəsilə tanınaraq, leksikon təhlili əsasında sözlərin sintezini təşkil edirdi. Qeyd edilən sistemin tanıma nəticəsi müəllifin yazısının keyfiyyətindən asılı olaraq 75-91% aralığında dəyişir. Əlyazma hərfləri müəllifdən asılı olaraq dəyişdiyi üçün, əlyazmanı tanımada ən əsas problem hərflərin siniflərə ayrılması olaraq qalır.

Neyron şəbəkələr 80-ci illərdə tanıma məsələlərində populyarlıq qazandığı üçün, onun əsasında fərqli sahələrə aid bir çox tanıma sistemləri qurulmuşdur [4, s.267-284]. Zaman keçdikcə, sistemlər mürəkkəbləşərək, daha çox tanıma dəqiqliyi tələbi ilə üzləşdilər. Öyrənmə nümunələri və onların sayı artdıqca neyron şəbəkələr vasitəsi ilə tanımanın dəqiqliyini artırmaq heç də həmişə mümkün olmurdu – dəqiqliyi artırmaq üçün intuitiv olaraq şəbəkə strukturu və hesablama alqoritmlərini dəyişmək təklif edilirdi ki, bu da heç də həmişə arzu edilən nəticəyə zəmanət vermirdi. Əsas problem öyrənmənin ideal olmasına baxmayaraq, tanımanın eyni dəqiqliyə malik olmaması kimi özünü büruzə verirdi.

Qeyd edilən problemi həll etmək üçün 90-cı illərdə V.N. Vapnik tərəfindən Struktur Risk Minimallaşdırması nəzəriyyəsi əsasında hazırlanmış öyrənmə və tanımanın uzlaşması üçün riyazi həll yollarını özündə cəmləşdirən Dayaq Vektorları Üsulu (Support Vector Machine) təklif edildi [5, s.93-110]. Bu məqalədə DVÜ üsulu vasitəsilə azərbaycan dilində latın əlifbası ilə yazılmış əlyazma hərflərinin tanınması tədqiq edilmişdir.

2. Məsələnin qoyuluşu. Tanıma sistemləri, verilmiş (x_i, y_i) , $i=1, \dots, l$ öyrənmə nümunələri əsasında təyin edilmiş, iki və ya daha çox sinfi bir-birindən ayıracaq f funksiyasına görə qərarın verilməsi prinsipinə əsaslanır. Burada x_i – i -ci nümunənin n -ölçülü əlamətlər vektorunun qiymətləri,


y_i - i -ci nümunənin uyğun obrazının qiymətidir. Öyrənmənin uğurla başa çatması f funksiyasının öyrənmə nümunələri ilə verdiyi nəticənin arzu edilən nəticədən fərqləri cəminin kiçik olması ilə təyin edilir. Bu fərqlərin cəmi empirik riski xarakterizə edir və aşağıdakı kimi təyin olunur:

$$R(\alpha, (x, y)) = \frac{1}{l} \sum_{i=1}^l L(y_i, f(x_i, \alpha)).$$

Adətən L funksiyası kvadratik xəta kimi seçilir:

$$L(y, f(x, \alpha)) = (y - f(x, \alpha))^2.$$

Qeyd edilən öyrənmə yanaşması Empirik Risk Minimallaşması (ERM) adlanır və süni neyron şəbəkələrin öyrədilməsi zamanı istifadə edilir. ERM üsulunda əsas çatışmazlıq f funksiyasını seçmək üçün heç bir qayda və ya şərtin verilməməsidir. Məhz bu səbəbdən, öyrənmə zamanı alınmış $R(\alpha, (x, y)^{\text{öyr}}$) xətası kiçik olsa belə, tanıma zamanı alınmış $R(\alpha, (x, y)^{\text{tan}})$ xəta böyük ola bilər. Tanıma problemlərini həll edərkən əsas məsələ öyrənmə və tanıma xətalalarının nümunə sayı l artdıqca uzlaşmasıdır (şəkil 1).



Şəkil 1. Nümunələrin sayından asılı olaraq öyrənmə və tanıma xətalalarının qiymətinin uzlaşması.

[5, s. 93-110]-də verilmiş SRM yanaşmasında əsas anlayışlardan biri olan VC (Vapnik-Chervonenkis) ölçüsü təklif edilmişdir, hansı ki h kimi işarələnməklə, verilmiş nümunələrin neçə variantda iki sinfə ayırılabilməsi xassəsini özündə əks etdirir.

ERM-dən fərqli olaraq, öyrənmə zamanı birbaşa olaraq riski minimallaşdırma əvəzinə, SRM-də ilk əvvəl verilmiş z_1, \dots, z_l müşahidələri (öyrənmə üçün nümunələr) üçün S funksiyalar çoxluğunda optimal VC ölçüsünə malik S_i , $i=1..m$ elementini və aşağıdakı şərtdə riskin minimal olması üçün S_i -dən uyğun funksiya seçmək tələb olunur:

$$R(\alpha) \leq R_{emp}(\alpha) + O\left(\frac{l}{h}\right). \quad (2.1)$$

Burada: l - müşahidələrin və ya öyrənmə nümunələrinin sayı, h - verilmiş öyrənmə çoxluğunu ayıra biləcək VC ölçüsü,

$O\left(\frac{l}{h}\right)$ - nümunə sayının VC ölçüsündən asılılığını təyin edən funksiyadır.

SVM-in əsas prinsipi şərti hər bir nümunəni müsbət (+1) və mənfi (-1) kimi işarələnmiş iki sinfi bir-birindən maksimum məsafədə ayıran hiperüstəvinin tapılmasıdır. Maksimum məsafə, $w \cdot x + b = 0$ hiperüstəvisi ilə ona ən yaxın olan əlamət vektorları arasında məsafələrinin cəmi $\frac{\|w\|^2}{2}$ kimi təyin edilir. Qeyd edilən “ən yaxın olan” əlamət vektorları “dayaq” (“support”) vektorları adlanır (şəkil 2c-də çevrələr ilə işarələnilib) və SVM üsulunun özəlliyi, öyrənmə zamanı bütün əlamət vektorlarının deyil, yalnız hiperfəzaya yaxın olan vektorların nəzərə alınmasıdır ki, bu öyrənmənin effektiv olmasına imkan yaradır. Həmin “dayaq” vektorlarının tapılması isə (2.1) düsturundakı VC ölçüsü ilə təyin edilir. Beləliklə, siniflər aşağıdakı şərt əsasında ayrılır:

$$w^T x_i + b \geq +1, \quad y_i = +1 \text{ üçün}, \quad (2.2)$$

$$w^T x_i + b \leq -1, \quad y_i = -1 \text{ üçün}, \quad i = 1, \dots, l. \quad (2.3)$$

(2.2) və (2.3) ümumi qaydada aşağıdakı kimi yazıla bilər:

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad i = 1, \dots, l. \quad (2.4)$$

Harada ki, ξ_i – müsbət qiymət alan sürüşmə əmsalıdır və siniflər tam ayrıla bilmədikdə ξ_i qiyməti vahiddən böyük qiymət alır. Bu halda ayrıla bilməyən vektorlar üçün ümumi xətanın qiyməti $\sum_i \xi_i$ kimi təyin edilir. Siniflər şəkil 2-dəki kimi ideal ayrılabiləndirsə, o halda ξ_i sifra bərabər olacaqdır.

Beləliklə, SVM-in öyrədilməsi üçün (2.4) şərti əsasında aşağıdakı funksiyanın minimumunun tapılmasıdır:

$$\min_{w,b} \Phi(w) = \frac{\|w\|^2}{2} + C \sum_{i=1}^l \xi_i. \quad (2.5)$$

Burada, C – SVM-i layihələndirən ekspert tərəfindən təyin edilən bir əmsaldır və yanlış klassifikasiya xətası və ayırma sərhəddi arasında nisbəti təyin etmək üçün istifadə edilir.

Yuxarıda qeyd edilən (2.4), (2.5) məsələsi kvadratik proqramlaşdırma məsələsidir və onun həlli üçün Laqranj vuruqları üsulu istifadə edilə bilər. C -nin sərbəst dəyişən olduğunu nəzərə alsaq, Laqranj funksiyasını aşağıdakı formada təyin edək:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i y_i (w^T x_i + b) + \sum_{i=1}^l \alpha_i. \quad (2.6)$$

Zəruri şərtlərdən istifadə edərək Laqranj funksiyanın w və b -yə görə törəmələrini aldıqda aşağıdakı şərtləri almış oluruq:

$$L'_w(w, b) = w - \sum_{i=1}^l \alpha_i y_i x_i = 0, \quad (2.7)$$

$$L'_b(w, b) = \sum_{i=1}^l \alpha_i y_i = 0. \quad (2.8)$$

(2.7) şərtini (2.6) düsturunda nəzərə alsaq, onda


$$L(w, b, \alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j x_i \cdot x_j. \quad (2.9)$$

DVÜ-nin öyrənilməsi (2.9)-dəki L funksiyanının (2.8) və

$$0 \leq \alpha_i \leq C, i = 1, \dots, l.$$

şərtləri daxilində maksimallaşdırılması vasitəsilə həyata keçirilir:

Burada α -nın sıfırdan böyük qiymətlər aldığı hallarda x əlamət vektorları “dayaq vektorları” sayılır və öyrənmədə ancaq onlar rol oynayır.



Şəkil 2. İki sinfi fərqli xətlərlə ayırma mümkünlüyü.

Parametrlərin sayının çoxluğu səbəbindən verilmiş optimallaşdırma məsələsini klassik kvadratik proqramlaşdırma məsələləri alqoritmləri ilə kompüterdə həll etmək çox zaman aldığı üçün effektiv sayılmır [12, s.213-236]. İşlənmiş sistemdə DVÜ öyrədilməsi üçün müasir alqoritmlər arasında effektiv sayılan LibSVM alqoritmindən istifadə edilmişdir [6].

2.1. Əlamətlərin seçilməsi. Məqalədə DVÜ öyrənmə modeli Azərbaycan latın əlifbasının kiçik hərflərinin əlyazması üzərində tədqiq edilmişdir. 60 müəllif tərəfindən yazılmış nümunələr 28x28 ölçüsünə normallaşdırılaraq, boz rəngin çalarları şəklində verilənlər bazasında saxlanmışdır (şəkil 3). Tanıma sistemlərində əsas məsələlərdən biri də öyrənilən və ya tanınan obyektlərdən maksimum dərəcədə informativ əlamətlərin alınmasıdır. Tədqiqatın əvvəlində əlamətlər kimi yalnız təsviri təşkil edən piksellərin qiyməti istifadə edilmişdir. Beləliklə, hər bir nümunə üçün, 0-dan 255-ə qədər qiymət alan, $28 \times 28 = 784$ əlamət yadda saxlamaq tələb olunacaqdır.

Müxtəlif seçilmiş əlamətlərin tanıma nəticəsinə təsirini araşdırmaq məqsədilə müqayisə üçün aşağıdakı daha üç növ əlamətlər istifadə olunub:

- 28x28 ölçülü təsvirə 2x2 ölçülü ortalama tətbiq edilməklə alınmış 14x14 ölçülü təsvir (şəkil 4). Bu halda ümumi əlamətlərin sayı 196 olacaqdır. Bu əlamətlərdə fərq sayın əvvəlkindən 4 dəfə az olmasından əlavə, mümkün xətlərin aradan qalxması da ola bilər. Belə ki, əgər eyni simvolun yazılışında piksellər üst-üstə düşməsə belə, hər 4 pikseldən ibarət kvadrat üçün orta qiymət hesablandıqı üçün, bu xəta aradan qalxacaqdır:

- Şaquli və üfüqi rast gəlinən qara pikselə (lərə) keçidin sayı. Bu 28x28 ölçülü təsvirdə hər bir şaquli və ya üfüqi mövqe üçün qeyri-qara (ağ və ya boz rəngin açıq çalarları) pikseldən qara pikselə keçidin sayının hesablanması ilə həyata keçirilir. Bu halda hər simvol üçün yalnız 56 (28 şaquli və 28 üfüqi mövqe üçün) əlamət saxlanması tələb olunacaqdır. Şəkil 5-də "ə" hərfinin nümunəsində 3 şaquli mövqedə əlamətlərin alınması göstərilmişdir. Şəkildə görüldüyü kimi, simvolun əvvəlində qara pikselə keçid 2 yerdə, ortada 3 yerdə, sonda isə 1 yerdə baş verir. Əgər şaquli ox üzrə qara pikselə rast gəlinməzsə, o halda həmin mövqe üçün əlamətin qiyməti sıfır götürüləcəkdir.


- Şaquli və üfüqi histoqramlar. Əvvəlki əlamətlərdən fərqli olaraq, burada hər mövqe üzrə qara piksellərin sayı hesablanaraq, əlamət olaraq saxlanılır. Bu əlamət növündə də 56 (28 şaquli və 28 üfüqi mövqe üçün) əlamət saxlanması tələb olunacaqdır.



Şəkil 3. 28x28 ölçüsünə normalaşdırılmış öyrənmə nümunələri



Şəkil 4. 14x14 ölçüsünə normalaşdırılmış öyrənmə nümunələri



Şəkil 5. Şaquli ox üzrə qara pikselə keçidlərin sayına nümunə.

Verilmiş öyrənmə nümunələrindən alınmış hər 3 növ əlamət əsasında sadə SVM üsulu ilə öyrənmə və tanımanın nəticəsi cədvəl 1-də göstərilmişdir:


Cədvəl 1
DVÜ üsulunun tətbiq nəticələri

Əlamət növü	28x28 piksel qiymətləri	14x14 piksel qiymətləri	Qara piksellərə keçid	Histoqram
Əlamət sayı	784	196	56	56
Tanıma nəticəsi	70.43%	70.96%	4.3%	6.72%

Cədvəl 1-də əlamətlərin növündən asılı olaraq tanıma nəticəsinin dəyişməsi görsənir və nəticənin yalnız son iki əlamətdə kəskin pisləşməsi müşahidə olunur. İkinci əlamət növündəki əlamətlərin sayının birincidən 4 dəfə az olmasına baxmayaraq, nəticə o qədər fərq etməmişdir.

Tanıma nəticəsinin aşağı olması tək əlamət sayı ilə deyil, həm də əlamətlərin informativ olmasından asılıdır. Hər-hansı bir obyektin tanıma sistemini qurarkən, həmin obyekt optimal olaraq xarakterizə edən əlamətləri tapmaq üçün riyazi və ya alqoritmik üsullar mövcud deyil və bu, adətən, intuitiv yolla edilir.

2.2. Nüvələrin istifadəsi. SVM modelində sinifləri ayıran sərhəd müstəvi kimi ifadə edildiyi üçün, öyrənib, tanıyacağımız əlamətlərin müstəvi ilə ayrılma bilməsi şərti vacibdir. Real öyrənmə məsələlərinin həllində ilkin əlamətlər, siniflərin tam olaraq düz xətlə ayrılması üçün heç də həmişə əlverişli olmur. Şəkil 6-da göstərildiyi haldakı kimi, bəzən əlamətlər fəzasını müstəvi ilə ayırmaq mümkün deyildir. Bu halda, nüvələrdən istifadə edərək, ilkin əlamətləri daha yüksək dərəcəli əlamət fəzasına köçürmək təklif edilir. Şəkil 7-də nümunə kimi götürülmüş “a”, “f”, “ğ” və “ə” simvollarının 196 əlamətinin 2-ölçülü koordinatda təsviri verilmişdir. Burada absis oxu [1,196] aralığında əlamətin indeksini, ordinat oxu isə [-1,1] aralığında əlamətin qiymətini göstərir. Şəkil 7,a-dan “a” və “f” simvollarının əlamətlərinin verilmiş aralıqda səpələnməsi və tam ayrılabilən olması görüldüyü halda, şəkil 7,b-də əlamətlərin yalnız [-0.6,0.35] aralığında paylanması və simvolların ayrılmasının qeyri-mümkünlüyü müşahidə olunur.



Şəkil 6. Solda “A” və “B” sinifləri düz xətlə ayrılma bilmədiyi halda, sağdakı halda sinifləri düz xətlə ayırmaq mümkün deyil.

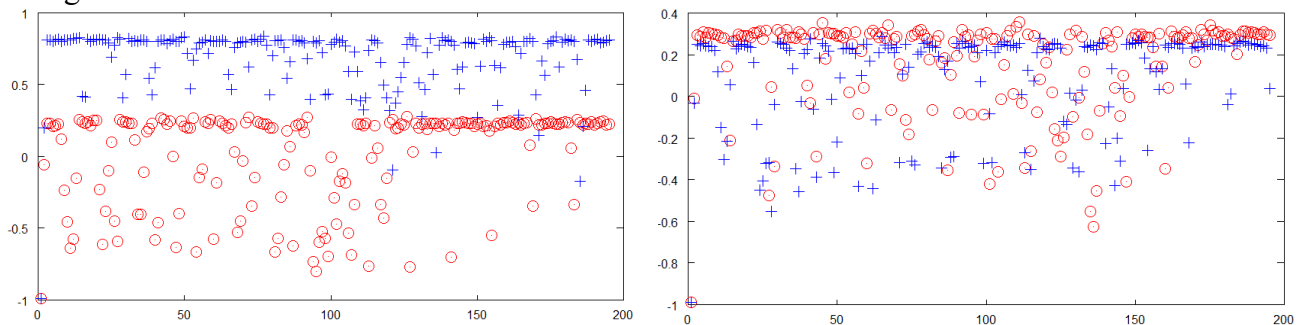
Cover teoreminə əsasən, əgər köçürmə qeyri-xətti və əlamət fəzasının ölçüsü kifayət qədər böyük olarsa, o halda giriş fəzası, siniflərin müstəvi ilə ayrılabiləcək yeni əlamət fəzasına köçürülə bilər [7, s. 326-334]. Qeyd edilən problemi həll etmək üçün, giriş fəzasını daha yüksək ölçülü əlamət fəzasına qeyri-xətti qaydada köçürmək lazımdır. Adı çəkilən köçürmə K ilə işarə edilən müəyyən nüvə funksiyaları vasitəsilə həyata keçirilə bilər.

Aşağıda bəzi nüvə funksiyalarının nümunələri göstərilmişdir:

- 1) Polinomial: $K(x, x_i) = (\gamma x^T x_i + b)^d$;
- 2) Gauss tipli: $K(x, x_i) = \exp\left(\frac{-\|x-x_i\|^2}{2\sigma^2}\right)$;
- 3) Sigmoid: $K(x, x_i) = \tanh(\gamma x^T x_i + b)$,

harada ki, x – ilkin əlamət vektorudur.


Şəkil 7-də göstərilən çətinliyi aradan qaldırmaq üçün Cover teoreminə əsaslanaraq, Gauss tipli nüvənin tətbiqi ilə, “ə” və “ğ” simvollarını $K(x_i, x_j)$, $i = 1, \dots, 196$; $j = 1, \dots, 196$ 3-ölçülü fəzaya köçürürük. Şəkil 8-də qeyd edilən simvolların 3-ölçülü fəzada təsviri göstərilmişdir. Təsvirin mürəkkəb olmaması üçün yalnız $i=90, \dots, 110$; $j=90, \dots, 110$ aralığında olan 400 əlamət göstərilmişdir. Təsvirdən görüldüyü kimi, əlamətlərin paylanmasında fərq yaranmışdır: “ə” simvolunun əlamətləri [0.9972, 0.9985] arasında paylandığı halda, “ğ” simvolunun əlamətləri [0.995, 0.9968] aralığındadır.




a) “+” kimi işarələnmiş “a” simvolu və “o” kimi işarələnmiş “f” simvolunun əlamətləri

b) “+” kimi işarələnmiş “ğ” simvolu və “o” kimi işarələnmiş “ə” simvolunun əlamətləri

Səkil 7. Simvolların əlamətlərinin 2-ölçülü fəzada təsviri.



a) “ə” simvolumunun əlamətləri



b) “ğ” simvolumunun əlamətləri

Səh 8. “ə” və “ğ” simvolların əlamətlərinin 3-ölçülü fəzadə təsviri.

3. *Ədədi eksperimentlərin nəticəsi.* Nüvələrin seçiminin effektivliyini təhlil etmək üçün təsadüfi seçilmiş parametrlərlə aparılan təcrübənin nəticəsi cədvəl 2-də göstərilmişdir. Burada hər bir əlamət və nüvə növü üçün alınmış ən yüksək göstərici qeyd edilmişdir. Cədvəldən görüldüyü kimi, nüvələrin istifadəsi nəticələri heç də böyük fərqlə yaxşılaşdırmamış, tanıma nəticəsini yalnız kiçik 2-4% qədər artırmışdır.

Cədvəl 2

Nüvələrin tətbiqindən sonra alınmış nəticələr

İstifadə edilən nüvə	Əlamət növü			
	28x28 piksel qiymətləri	14x14 piksel qiymətləri	Qara piksellərə keçid	Histoqram
	Əlamət sayı			
	784	196	56	56
Çoxhədli	72.58%	73.65%	4.03%	8.06%
Gauss	5.91%	4.03%	3.76%	3.76%
Sigmoid	3.22%	3.22%	3.76%	3.22%

Nüvələrin istifadəsi zamanı seçilmiş parametrlər və alınmış nəticə cədvəl 3-də göstərilmişdir. Aparılmış təcrübələrin nəticələri göstərir ki, nüvələrin istifadəsi zamanı tək nüvə növünün deyil, həm də parametrlərin düzgün seçilməsi vacib rol oynayır.

Tanıma dəqiqliyini artırmaq məqsədilə işlənmiş sistemdə optimal nüvə və parametrlərin seçilməsi üçün öyrənmə sistemlərində geniş istifadə edilən “qarşılıqlı yoxlama” (cross-validation) üsulundan istifadə edilmişdir [8, s.1137-1143]. Bu məqsədlə “k-fold” üsulu tətbiq edilmişdir [9, s.56-65; 10, s.575-583], hansı ki, öyrənmə nümunələrini bərabər sayda k hissəyə ayıraraq, nüvə ilə 1 hissəni tanıma(yoxlama), digər k-1 hissəni isə müxtəlif parametrlərlə öyrənmə üçün istifadə etməyi təklif edir. Parametrlərin əvvəldən verilmiş qiymətləri ardıcıl olaraq tətbiq edilir və ən yaxşı nəticə halında alınmış parametrlər yadda saxlanılır. [11] işindəki tövsiyəyə görə parametrlərin qiymətləri logarifmik sıra kimi seçilmişdir (qüvvəti xarakterizə edən d parametri xaric olmaqla):

$$C = \{2^{-5}, 2^{-3}, \dots, 2^{13}, 2^{15}\};$$

$$\gamma = \{2^{-15}, 2^{-13}, \dots, 2^3, 2^5\};$$

$$b, \sigma = \{2^{-15}, 2^{-13}, \dots, 2^3, 2^5\};$$

Cədvəl 3
Nüvələrin müxtəlif parametrlərlə istifadəsi

Əlamət növü	Nüvə	γ	C	b/σ	d	Nəticə
1	Çoxhədli	0.1	100		3	70.69%
		0.1	100		5	66.93%
		3	3		4	68.81%
		0.001	3		2	72.58%
	Gauss		100	0.001		5.91%
			10	0.1		4.03%
Sigmoid	0.1	3		5	3.22%	
2	Çoxhədli	0.1	100		3	73.38%
		0.1	100		5	72.58%
		0.001	3		4	73.65%
		10	0.01		4	73.65%
	10	0.01		2	72.58%	
	Gauss		100	10		4.03%
Sigmoid	10	0.01		5	3.22%	
3	Çoxhədli	0.1	5		3	4.03%
		0.1	5		4	4.03%
		0.1	0.01		5	3.23%
	Gauss		100	0.1		3.23%
			10	0.01		3.76%
			1	0.001		3.49%
			0.1	5		3.49%
	Sigmoid	0.01	100		2	3.22%
		10	0.1		2	3.76%
1000		0.01		2	3.22%	
4	Sigmoid	1000	0.01		2	3.22%
		10	0.1		2	3.22%
	Gauss		0.01	0.1		3.22%
			100	0.01		3.76%
			10	5		3.22%
	Çoxhədli	0.1	5		3	8.06%
0.1		5		4	8.06%	

Hər bir əlamət növü üzərində $k=5$ parametri ilə aparılmış “k-fold” qarşılıqlı yoxlamasının nəticəsi əsasında optimal nüvə və parametrlər cədvəl 4-də göstərilmişdir. Cədvəldən, ən yüksək nəticəni 196 dəyişəndən ibarət olan əlamətləri öyrənmək üçün tətbiq edilmiş Gauss nüvəsinin verdiyi görünür. Əvvəlki təcrübədə Gauss tipli nüvənin verdiyi cədvəl 4-də verilmiş nəticələrə baxmayaraq, “k-fold” üsulu ilə müxtəlif parametrlərin kombinasiyaları ilə aparılmış təcrübə müsbət nəticə verərək, ilk tanıma keyfiyyətindən 10% yüksək dəqiqlik almağa imkan vermişdir.

Cədvəl 4
“Qarşılıqlı yoxlama” üsulu ilə tapılmış optimal nüvə və parametrlər

Əlamət növü	Optimal nüvə	γ	C	b/σ	d	Nəticə
28x28 piksel qiymətləri	Nüvəsiz		0.078		2	78%
14x14 piksel qiymətləri	Gauss		8	0.03125		80%
Qara piksellərə keçid	Çoxhədli	0.125	0.00048	0	3	6%
Histoqram	Çoxhədli	0.0078	0.125	0	3	8%

Tanıma sistemlərində dəqiqliyin yüksək olması üçün siniflərin bir-birindən maksimum dərəcədə ayrılmalı bilinəcək olması vacibdir. Sinifləri xarakterizə edən əlamətlər nə qədər fərqli olarsa, tanıma dəqiqliyi də bir o qədər yüksək olar. İşlənmiş sistemdə tanıma dəqiqliyini yüksəltmək məqsədilə siniflərin fərqliliyi təhlil edilmişdir. Bu məqsədlə tanıma zamanı ən çox yanlış tanınmış simvollar və onların səhv salındığı simvollar aydınlaşdırılmışdır (cədvəl 5).

Cədvəl 5
Ən çox yanlış tanınan simvollar

Yoxlanılan simvol	<i>e</i>	<i>t</i>	<i>u</i>	<i>g</i>	<i>l</i>	<i>ə</i>
Yanlış təklif edilən simvol	<i>k, l</i>	<i>ğ, h, l</i>	<i>a, d, v</i>	<i>q, y, o</i>	<i>ı, b</i>	<i>ö, s, z, v</i>

Cədvəl 5-dən göründüyü kimi, əsasən “l” və “ı” simvolları digərləri ilə daha çox yanlış salınır. Tanıma sisteminin dəqiqliyini daha da artırmaq üçün simvolları əlamətlərə görə siniflərə ayıraraq, hər sinif üçün ayrı DVÜ modeli qurmaq olar.

4. Nəticə. İlk əlamətlər üzərində aparılmış çoxsaylı təcrübələrin nəticəsi göstərir ki, Dayağ Vektorları Üsulunun tətbiqi tək əlyazmanı tanıma deyil, həm də digər tanıma sistemlərində uğurla istifadə edilə bilər. Məqalədə aparılmış tədqiqat nəticəsində aşağıda nəticələr alınmışdır:

1) Sinifləri təmsil edən əlamətlərin sayı öyrənməyə sərf olunan zamana təsir etsə də, tanıma dəqiqliyi üçün əsas rol oynamır. Əlamətlərdə əsas onların informativ və hər sinif üçün maksimal dərəcədə unikal olmasıdır. Əlamətləri seçərkən, məlumatın paylanması, ayrılacaq siniflərin sayı və ayırma funksiyasının seçilməsinə fikir vermək lazımdır.

2) Tanıma sistemi işləyərkən, tək bir yox, bir neçə əlamət qrupundan istifadə edilərək, “qarşılıqlı yoxlama” üsulu vasitəsilə hansı qrup əlamətin daha faydalı olmasına qərar verilə bilər.

3) Nüvələrin parametrlərini seçmək üçün “qarşılıqlı yoxlama” üsulundan istifadə etmək lazımdır. Parametrlərin qiymətlərinin loqarifmik silsilə kimi seçilməsi daha az say ilə daha tez nəticə almağa kömək edə bilər. Sonradan ən yaxşı nəticə vermiş parametrlərin qiymətləri ətrafında təkrar “qarşılıqlı yoxlama”nın aparılması daha dəqiq parametrlərin təyin edilməsində yardım edə bilər.

4) Polinomial nüvələrin istifadəsi zamanı, qüvvəti 5-dən çox artırmağın effekti böyük olmur. Bu yalnız hesablamaları mürəkkəbləşdirir. Törəmə əlamətləri müsbət və mənfi qiymətlər olan halda tədqiq edə bilmək üçün tək və cüt qüvvələrin hər birini yoxlamaq lazımdır.

Ədəbiyyat

1. R.G. Casey and E. Lecolinet. Strategies in character segmentation: A survey/ Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, Canada, pp. 1028-1033, 1995.
2. M. Chen. Off-Line Handwritten Word Recognition Using Hidden Markov Models/ Proc. United States Postal Service Advanced Technology Conference, Washington, D.C., pp. 563-579, Nov. 1992.
3. K.R. Aida-Zade, C.Z. Həsənov. “Cursive handwritten Azerbaijani latin text segmentation based on word baseline”. International Symposium on Innovations in Intelligent Systems and Applications, June 29-July 1, 2009.
4. S. Wesolkowski. “Cursive script recognition: A survey”. Handwriting and Drawing Research –Basic and Advanced Issues, IOS Press, pp. 267-284, 1996.
5. V.N. Vapnik. The Nature of Statistical Learning Theory. Springer-Verlag, New York, pp.93-110, 1995.
6. C-C. Chang, C-J. Lin. LIBSVM : a library for support vector machines. ACM Transactions on Intelligent Systems and Technology, 2:27:1--27:27, 2011.
7. T.M. Cover. "Geometrical and Statistical properties of systems of linear inequalities with applications in pattern recognition". IEEE Transactions on Electronic Computers. EC-14: 326–334. 1965.
8. R. Kohavi. "A study of cross-validation and bootstrap for accuracy estimation and model selection". Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence (San Mateo, CA: Morgan Kaufmann) 2 (12): 1137–1143. 1995.
9. F. Mosteller. "A k-sample slippage test for an extreme population". Annals of Mathematical Statistics 19 (1): 58–65. 1948.

10. P. Picard, D. Cook (1984). "Cross-Validation of Regression Models". Journal of the American Statistical Association 79(387): 575–583.
11. S. Arlot, A. Celisse. A survey of cross-validation procedures for model selection. Statist. Surv. 4, 40-79. 2010.
12. H. Brun, S.-W. Lee and A. Verri (Eds.). Applications of Support Vector Machines for Pattern Recognition: A Survey. SVM 2002, LNCS 2388, pp. 213-236. 2002.

УДК 004.021

К.Р. Айда-заде. Д.З. Гасанов

Анализ применения Метода Опорных Векторов в распознавании азербайджанских рукописных букв

Рассматриваются специфика и способы применения метода опорных векторов (МОВ), одного из новейших методов, используемых в компьютерных системах обучения и распознавания. Каждый этап процесса распознавания - первичная обработка, выделение признаков, обучение и распознавание, рассмотрены и проанализированы в отдельности, определена их роль в процессе распознавания. В завершающей части статьи указаны результаты проведенных экспериментов и перечислены основные факторы, влияющие на эффективность применения МОВ.

Ключевые слова: рукопись, распознавание, признаки, опорные векторы, SVM, метод опорных векторов

K.R. Aida-zade, J.Z. Hasanov

An analysis of the Azerbaijani handwritten letter recognition using Support Vector Machine

The authors depict the properties and application of one of the modern methods used in machine learning – support vector machines (SVM). Initial processing, feature extraction, learning and recognition parts of the system are analyzed in detail; their role in recognition systems is shown. The paper is summarized with recommendations about the use the SVM and the results of the experiments.

Keywords: handwriting, recognition, features, support vectors, SVM, support vector machine