

РАЗБИВАЊЕ НА МНОЖЕСТВОТО ОБЕЛЕЖЈА ЗА КОМБИНИРАЊЕ НА КЛАСИФИКАТОРИ PARTITIONING OF THE FEATURE SET FOR CLASSIFIER COOPERATIONS

ДУШАН ЧАКМАКОВ¹, ДЕЈАН ЃОРЃЕВИК²

DEJAN GORGEVIK¹, DUSAN CAKMAKOV²

¹ Универзитет "Св. Кирил и Методиј", Машински факултет, Оддел за математика и информатика, Карпош II б.б., П.фах 464, 1000 Скопје, Македонија, dusan@mf.ukim.edu.mk

² Универзитет "Св. Кирил и Методиј", Електротехнички факултет, Институт за компјутерска техника и автоматика, Карпош II б.б., П.фах 574, 1000 Скопје, Македонија, dejan@etf.ukim.edu.mk

¹ University "Sv. Kiril i Metodij", Faculty of Electrical Eng., Department of Computer Science and Information Technology, Karpos II bb, POBox 574, 1000 Skopje, Macedonia, dejan@etf.ukim.edu.mk

² University "Sv. Kiril i Metodij", Faculty of Mechanical Eng., Department of Mathematics and Computer Science, Karpos II bb, POBox 464, 1000 Skopje, Macedonia, dusan@mf.ukim.edu.mk

Айџираќи - Во овој труд се разгледани различни комбинирања на класификатори базирани на машините со носечки вектори (МНВ) што работат на две множества обележја за препознавање на со рака испишани цифри. Испитувањата ги почнавме со множество составено од структурни и статистички обележја и соодветен МНВ класификатор применет врз целото множество обележја. Понатаму беа испитувани различни разбивања на множеството обележја како и предностите и слабостите на различните комбинирања на класификаторите креирани врз одделните множества обележја. Добиените резултати покажуваат дека е тешко да се надминат перформансите на еден МНВ класификатор применет праволиниски на целото множество обележја. Дополнително е покажано дека разбивањето на множеството обележја според природата на обележјата (структурни и статистички) не е секогаш најдобриот пат за креирање на систем базиран на комбинирање на класификатори. Овие резултати наметнуваат потреба од посебни процедури за селекција на обележја што на оптимален начин ќе го разбиваат множеството обележја за системите што користат комбинирање на класификатори.

Abstract – In this paper, various cooperation schemes of SVM (Support Vector Machine) classifiers applied on two feature sets for handwritten digit recognition are examined. We start with a feature set composed of structural and statistical features and corresponding SVM classifier applied on the complete feature set. Later, we investigate the various partitions of the feature set as well as the advantages and weaknesses of various decision fusion schemes applied on SVM classifiers designed for partitioned feature sets. The obtained results show that it is difficult to exceed the recognition rate of a single SVM classifier applied straightforwardly on the complete feature set. Additionally, we show that the partitioning of the feature set according to feature nature (structural and statistical features) is not always the best way for designing classifier cooperation schemes. These results impose need of special feature selection procedures for optimal partitioning of the feature set for classifier cooperation schemes.

Index terms – classification, committee, features, rejection, reliability

Индексни термини - класификација, кооперација, обележја, отфрлање, доверливост

1. ВОВЕД

Стандардниот пристап за препознавање на симболи се врти околу два чекора, екстракција на обележја, каде што се развива погодено претставување на обликот и класификација, каде што се дефинираат правила за одделување на класите на облиците. Покажано е дека комбинирањето на обележја од различна природа преку комбинирање на соодветните класификатори е ветувачки пристап во системите за препознавање со рака испишани симболи [1], [2], [3], [4], [5]. Информациите од повеќе извори што се одделно обработени често можат корисно да се

The classical paradigm for character recognition is concentrated around two steps, feature extraction, where an appropriate representation of the pattern is developed, and classification, where decision rules for separating pattern classes are defined. Combining features of different nature and the corresponding classifiers has been shown to be a promising approach in handwritten recognition systems [1], [2], [3], [4], [5]. Data from more than one source that are processed separately can often be profitably re-combined to produce more concise, more complete and/or more accurate situation description.

In this paper, classification systems for handwritten digit recognition using two different feature families and SVM classifiers [6] are examined. Following widely used terminology, our feature families are referenced as structural and statistical feature sets [7]. We start with a SVM classifier applied on both feature families as one feature set. These

искомбинираат давајќи покомплетен и поточен приказ на реалната ситуација.

Во овој труд се разгледани системи за класификација на со рака испишани цифри користејќи две различни фамилии на обележја и МНВ класификатори [6]. Следејќи ја широко распространетата терминологија, ние ги нарекуваме нашите фамилии обележја структурни и статистички [7]. Испитувањата ги започнавме со еден МНВ класификатор применет на двете фамилии обележја како едно множество. Овие резултати беа база за понатамошните испитувања. Понатаму користевме два МНВ класификатора што работат одделно врз структурните и статистичките фамилии обележја и ги испитувавме нивните комбинирања. Според нашата терминологија, ние го разбивме комплетното множество обележја според нивната природа на структурно и статистичко множество. Ние испитавме различни шеми на комбинирање и ги дадовме соодветните резултати на препознавање. За зголемување на доверливоста на системот беа воведени критериуми за отфрлање на несигурните класификации како дел од шемите на комбинирање.

Добиените резултати покажуваат дека со комбинирање на класификатори е тешко со да се достигне нивото на препознавање на еден класификатор применет врз множеството што ги обединува двете фамилии обележја. Сепак, шемите на комбинирање даваат подобра можност за подесување на трговијата меѓу препознавањето и доверливоста и ја намалуваат комплексноста на класификаторот како и неговата потреба од примероци за обучување.

Дополнително, ние ја испитувавме и корисноста на разбивањето на множеството обележја според природата на добиените обележја. Истражувачите на комбинирањата на класификатори премолчено се согласуваат дека групирањето на обележјата според нивната природа (т.е. разбивањето на комплетното множество) е прифатлив пристап за креирање на систем за препознавање облици што користи комбинирање на класификатори. Основната претпоставка е дека различните обележја (по потекло, т.е. природа) се разумно независни. Тие го "гледаат" обликот на различен начин, па така и одлуките на соодветните индивидуални класификатори може корисно да се искомбинираат за да се добие поточно препознавање. Нашите резултати покажуваат дека структурните и статистичките обележја што широко се користат во системите за препознавање облици базирани на комбинирање на класификатори не се секогаш најдобар начин на разбивање на множеството обележја. Овој резултат наметнува потреба од развој на посебни постапки за селекција на обележја што на оптимален начин ќе го разбијат комплетното множество за системите на препознавање базирани на комбинирање на класификатори.

Целта на овој труд не е да се натпреварува со нивоата на препознавање на другите системи за препознавање со рака испишани цифри [8] туку да се

results serve as a basis for future investigations. Further, we used two SVM classifiers that work on the structural and statistical feature families and examined their cooperation using statistical decision fusion. In our terminology, we partition the complete feature set according to the feature nature into structural and statistical feature sets. Different statistical cooperation schemes were examined and corresponding recognition results are presented. In order to improve the system reliability, we introduced rejection criteria as a part of the classifier cooperation schemes.

The presented results show that it is difficult to achieve the recognition rate of single classifier applied on the feature set that includes both feature families by combining the individual classifier decisions. However, the classifier cooperation schemes offer better possibility for fine tuning of the recognition versus the reliability tradeoff and reduce both, the classifier complexity and the need for samples.

Additionally, we tackle the problem of usefulness of partitioning of the feature set according to the nature of the obtained features. The researchers in the area of combining classifier tacitly agree that partitioning of the features according to their nature is an acceptable approach for designing pattern recognition systems based on classifier cooperation. The basic supposition is that different features (by their origin) can be considered as reasonably independent. They "see" the same pattern from different points of view and consequently, corresponding individual classifier decisions can be profitably re-combined to produce more accurate recognition. Our results show that statistical and structural features, widely used for designing pattern recognition systems based on classifier cooperation schemes is not always the best way to partition the feature set. This result imposes need of special feature selection procedures for optimal partitioning of the feature set in cases of classifier decision fusion applied on different feature families.

Our goals in this paper are to examine usefulness of our feature extraction and selection technique, to study different classifier cooperation schemes and to investigate usefulness of partitioning of the feature set according to the nature of the features rather than to compete with the recognition rates of other handwritten digit recognition systems [8].

2. THE SYSTEM ARCHITECTURE

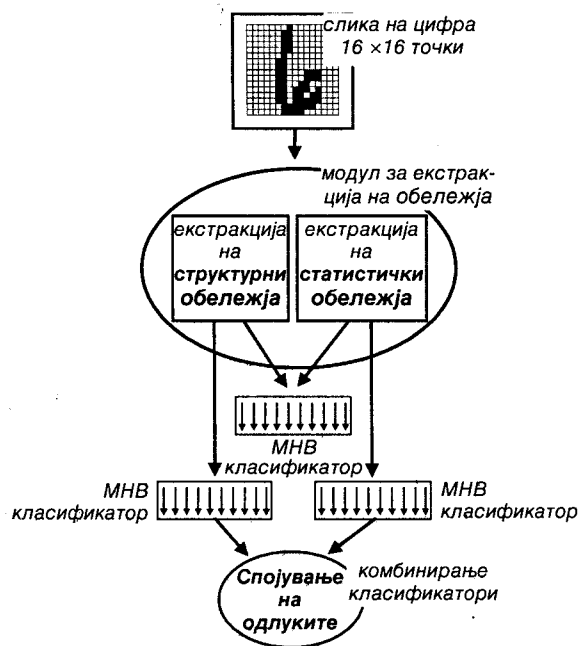
The recognition system is constructed around a modular architecture of feature extraction and digit classification units. Preprocessed image is an input for the feature extraction module, which transfers the extracted features toward SVM classifiers (see Fig. 1).

From the digit images with resolution of 128×128 pixels, we have obtained 16×16 binary images on which the smoothing and centralizing preprocessing techniques have been applied. We have extracted 116 features that are classified as 54 structural and 62 statistical. The both feature families as one set are forwarded to the SVM classifier and obtained results are basis for future comparisons.

испита корисноста на нашите техники за екстракција на обележја, корисноста на различните шеми на комбинирање на класификатори и корисноста на разбивањето на множеството обележја според нивната природа.

2. АРХИТЕКТУРА НА СИСТЕМОТ

Системот за препознавање е изграден околу модулите за екстракција на обележја и класификација на цифрите. Претпроцесираната слика на цифрата е влез за модулот за екстракција на обележја од каде што обележјата се праќаат кон МНВ класификаторите (види Сл. 1).



Слика 1. Архитектура на системот

Сликите на цифрите со резолуција 128x128 точки се сведени на бинарни слики со резолуција 16x16 точки над кои е извршено израмнување и центрирање. Ние екстрахиравме 116 обележја при што 54 се структурни и 62 статистички. Двете фамилии обележја како едно множество се пратени кон МНВ класификатор и така добиените резултати се основа за идните споредби.

Структурните и статистичките обележја поодделно се исто така пратени кон засебни МНВ класификатори, а добиените излези се комбинирани користејќи различни статистички шеми на комбинирање. Во тој момент се воведени и критериумите за отфрлање на несигурните класификации и пресметани се соодветните вредности за доверливоста на системот.

3. ЕКСТРАКЦИЈА НА ОБЕЛЕЖЈАТА

Структурните обележја се зависни од доменот. Нивната природа и техниките за екстракција многу зависат од објектот што се препознава.

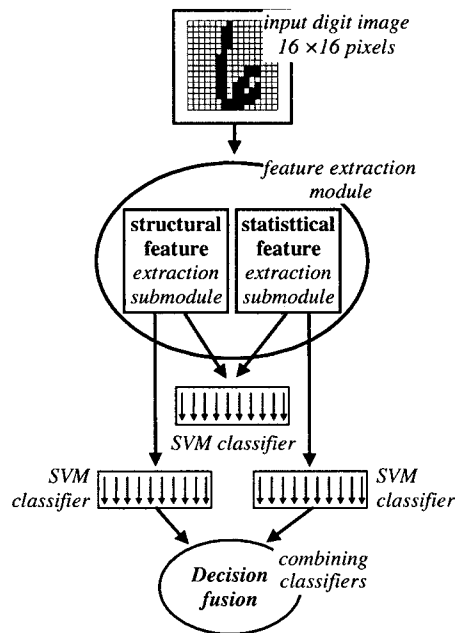


Fig. 1. The architecture of the system


The structural and statistical feature sets are also forwarded to the separate SVM classifiers, and obtained classifier outputs are combined using statistical cooperation schemes. On this level, rejection criteria are introduced and the corresponding system reliabilities are calculated.

3. THE FEATURE EXTRACTION MODULE

The structural feature set is a domain dependent set. Its nature and the techniques implemented for detection and extraction are strongly dependent of the nature of the objects to be recognized.

The first step in creating of the structural feature set is defining a reasonable set of elementary shape primitives for digit constructions. We have proposed 27 elementary primitives showed in Fig. 2. The digit image is searched for these primitives twice: firstly on the original digit image orientation, and secondly on the rotated digit image for 90°. So, the total number of primitives is 54, and that is the number of the elements in the structural feature set.

The detection and the extraction of the structural features are performed by dividing the image binary matrix into two, three, four and six sub-regions. The existing shape in each of those sub-regions is compared with the proposed primitives in the same sub-regions whose existence is expected.



Слика 2. Регионите и елементарните облици
Fig. 2. Image sub-regions and the elementary primitives

Првиот чекор при креирањето на структурните обележја е дефинирањето на разумно множество елементарни облици од кои цифрата може да се конструира. Ние предложивме 27 елементарни облици прикажани на Сл. 2. Елементарните облици на сликата на цифрата се бараат двапати: прво на оригиналната ориентација, а потоа на истата слика ротирана за 90°. Така вкупниот број елементарни облици е 54, па толкав е и бројот на структурните обележја. Детекцијата и екстракцијата на структурните обележја се прави со поделба на матрицата на цифрата на два, три, четири и шест региони. Облиците во секој од овие региони се споредува со предложените елементарни облици во истите региони каде што се очекува нивното присуство.

Така, структурното множество на обележја се состои од 54 вредности на пресметаните сличности [9] меѓу облиците во соодветните региони и соодветните елементарни облици.

Статистичкото множество обележја се состои од 62 вредности добиени преку пресметка на густините на црни точки во различни региони на сликата на цифрата. Првите 54 статистички обележја се добиваат од хистограмите и тоа од вертикалните (16), хоризонталните (16) и двете дијагонални (22) проекции (по 5 точки лево и десно од главната и споредната дијагонала). Последните 8 обележја се добиени од различни региони (зони) на сликата како што е прикажано на Сл. 3.

Овој тип на обележја во различна форма се користени во многу системи за препознавање симболи (на пример [10]).

4. РЕЗУЛТАТИ

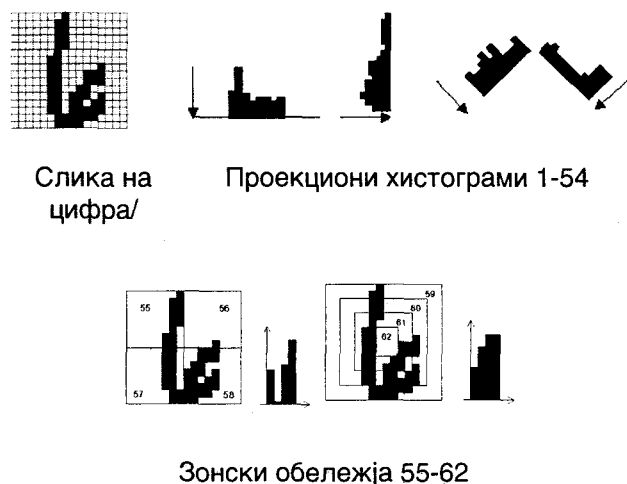
Базата за експерименти е екстракција од NIST (National Institute of Standards and Technology) базата на со рака испишани цифри (види Сл. 4). Вкупниот број од 23.898 примероци на цифри е поделен на две групи и тоа 17.952 примероци за фазата на обучување и 5.946 примероци за фазата на тестирање. Цифрите од базата се организирани така што цифрите за тестирање припаѓаат на различни пишувачи од цифрите за обучување.

Ние користевме МНВ класификатор со Гаусово јадро. Поради големиот број примероци беше користена поробусна варијанта на софтвер (SVM Torch) за обучување на МНВ класификаторите [11].

Излезите на овој класификатор применет на нашите примероци се во интервалот [-8, 5]. Да ги означиме излезите од класификаторот во опаѓачки редослед со O_1, O_2, \dots, O_{10} ($O_1 \geq O_2 \geq \dots \geq O_{10}$). Нашиот критериум за отфрлање на несигурните класификации се базира на првите два излеза. Секој примерок за кој највисокиот излез од класификаторот O_1 е помал од даден праг T_1 ($O_1 < T_1$) или за кој разликата меѓу двата највисоки излези е помала од даден праг

Thus, the structural feature set is composed of 54 values of the calculated similarities [9] between the found shapes in the corresponding sub-regions and the corresponding elementary primitives.

The statistical feature set is composed of 62 features that give the pixel-based information presented by the densities of the lit pixels in various regions of the digit image. The first 54 statistical features are obtained from the projection histograms obtained by the vertical (16), horizontal (16) and two diagonal (22) projections (5 pixels left and right around the main diagonals). The last 8 features are obtained from the zone-pattern regions showed in Figure 3.



Сл. 3. Проекциони хистограми и зонски обележја
Fig. 3. Projection histograms and

This kind of features in different forms has been exploited in many pattern recognition systems [e.g. 10].

4. THE RECOGNITION RESULTS

The database for our experiments is an extraction of the NIST (National Institute of Standards and Technology) handwritten digit database (see Fig. 4). The total number of 23.898 digit images is divided into two groups, 17.952 images for the training phase and 5.946 images for the test phase. The digits from the original database are rearranged so that digits in the test set belong to different writers from those in the learning set.

We have used a SVM classifier with Gaussian kernel. Because of the large number of samples, a more robust variation of SVM training software (Torch3) has been used [11].

The outputs of this classifier applied on our samples fall in [-8, 5] interval. Let us denote the classifier outputs in descending order by O_1, O_2, \dots, O_{10} ($O_1 \geq O_2 \geq \dots \geq O_{10}$). We have used a rejection criterion based on the top two classifier

T_2 ($O_1 - O_2 < T_2$) се отфрла како несигурна класификација. Подесувајќи ги овие прагови за да се добие доверливост од најмалку 99% ние ги добивме резултатите прикажани во табелата 1.

Табела 1. Нивоата на препознавање за структурните, статистичките и двете фамилии обележја заедно

| МНВ (Гаусово јадро) | Преп. (%) | T_1, T_2 | ДПреп. (%) | Погр. (%) | Отфр. (%) | Довер. (%) |
|-------------------------|-----------|----------------|------------|-----------|-----------|------------|
| Структурни обележја | 94.92 | 0.382, 1.4626 | 81.97 | 0.81 | 17.22 | 99.02 |
| Статистички обележја | 97.01 | -0.533, 0.9988 | 92.40 | 0.92 | 6.68 | 99.01 |
| Струк. + Стат. обележја | 97.73 | 0.0056, 0.577 | 94.76 | 0.94 | 4.29 | 99.02 |


Преп. е нивото на препознавање на класификаторот. ДПреп., Погр. и Отфр. ги означуваат нивоата на препознаени, погрешно препознаени и отфрлени примероци од множеството за тестирање за доверливост од најмалку 99% добиени со критериум за отфрлање што ги користи дадените вредности за праговите T_1 и T_2 . Довер. означува доверливост што се добива со формулата Довер. = ДПреп./ $(100\% - \text{Отфр.})$. Овие резултати покажуваат дека статистичкото множество обележја дава повисоко ниво на препознавање од структурното. Сепак, нивото на препознавање од статистичките обележја е за повеќе од 0.7% пониско од она добиено со класификатор применет на целокупното множество обележја.

4.1 Комбинирање на одлуките од структурното и статистичкото множества обележја

Шемите за комбинирање се изградени околу два МНВ класификатора што прават класификација одделно со помош на структурното и статистичкото множество обележја. Во табелата 2 се дадени нивоата на препознавање на различни шеми за комбинирање на класификаторите. Тука користевме исти критериуми за отфрлање на примероците како во табелата 1. Вредностите за праговите T_1 и T_2 се повторно така избрани да се добие доверливост од најмалку 99%.

Методите за комбинирање: Производ, Демпстерово правило, Неодреден интеграл и Одлучувачките шаблони бараат веројатносни излези. За пресликување на оригиналните излези во интервал $[0, 1]$ ја користевме функцијата $1/(1+e^{-x})$.

За донесување одлука, првите четири комбинирања користат максимум од сумата, максимум од производот, максимум од максимумите и максимум од минимумите на соодветните парови на излезите од класификаторите [12]. Демпстеровото правило ги користи неодреденостите во изборите на класификаторите преку доделување на помала доверба на



Слика 4. 100 примероци на цифри
Fig. 4. 100 handwritten samples

sifier outputs. Each sample for which the highest classifier output O_1 is smaller than a certain threshold T_1 ($O_1 < T_1$) or for which the difference between the top two classifier outputs is smaller than a certain threshold T_2 ($O_1 - O_2 < T_2$) is rejected. Varying these thresholds to obtain reliability of at least 99% we have obtained the results shown in Table 1.

Table 1. Recognition rates on the structural, statistical and both feature families

| SVM (Gaussian kernel) | Recog (%) | T_1, T_2 | RRecog. (%) | Miscl. (%) | Reject. (%) | Reliab. (%) |
|-----------------------------------|-----------|----------------|-------------|------------|-------------|-------------|
| Structural features | 94.92 | 0.382, 1.4626 | 81.97 | 0.81 | 17.22 | 99.02 |
| Statistical features | 97.01 | -0.533, 0.9988 | 92.40 | 0.92 | 6.68 | 99.01 |
| Structural + Statistical features | 97.73 | 0.0056, 0.577 | 94.76 | 0.94 | 4.29 | 99.02 |

Recog. is the classifier recognition rate. RRecog., Miscl. and Reject. denote the recognition, misclassification and rejection rates for reliability of at least 99% provided by the rejection criterion using the corresponding values of T_1 and T_2 . Reliab. denotes the reliability that is calculated as Reliab. = RRecog./ $(100\% - \text{Reject.})$. These results show that the statistical feature set has stronger discrimination power and provides better recognition rate. However, the recognition rate of the statistical feature set is more than 0.7 percent lower than the recognition rate of the classifier applied to the complete feature set.

4.1 Decision Fusion on Statistical and Structural Feature Sets

The classifier cooperation schemes are built around two SVM classifiers performing classification separately on structural and statistical feature families. In Table 2, the

помалку сигурните избори [13]. Наивното Бајесово комбинирање ги користи конфузионите матрици на класификаторите за проценка на сигурноста на нивните одлуки [13]. Пребројувањето на Борда е една генерализација на комбинирање со мнозинско гласање [14]. Неопределениот интеграл бара максимален степен на согласност меѓу објективните вредности (добиели од сортираните излези на класификаторите за конкретна класа) и очекувањата (добиели како мери на неопределеност на двата класификатора) [15]. Ние исто така користевме неколку Одлучувачки шаблони за комбинирање на класификатори дадени во [16]. Динамичкиот просек користи динамички доделени тежини што се подесуваат така што ќе бидат пропорционални на сигурностите на поделните излези од класификаторите, а не на глобално избрани тежини како кај Обоштениот комитет [17]. Комбинирањето преку Обоштениот комитет се базира на тежинската сума на одлуките на класификаторите [18]. Модификуваниот Обоштен комитет се разликува од Обоштениот комитет само по избраните тежини кои се различни за секоја класа. Со други зборови, ние користевме вектор од тежини наместо една заедничка тежина по класификатор.

Неколку резултати од Табелата 2 заслужуваат внимание. Најдобри нивоа на препознавање (Преп. > 97.70%) се добиени од пет шеми на комбинирање. Да забележиме дека овие резултати се речиси идентични со нивото на препознавање на МНВ класификаторот што ги користи двете фамилии обележја како едно множество (види Табела 1).

Од друга страна, најдобри нивоа на препознавање за доверливост од 99% се добиени со шемите 21 (Обоштен комитет) и 2 (Производ). Овие резултати се значително подобри од соодветните резултати дадени во Табелата 1. Генерално, шемите на комбинирање со критериуми за отфрлање на несигурните класификации нудат повисоки нивоа на препознавање во споредба со МНВ класификаторот што ги користи двете фамилии обележја како едно множество (види Табела 1).

4.2 Комбинирање на одлуките при случајни разбивања на множеството обележја

За да ја испитаме корисноста на групирањето на обележјата според нивната "природа" ние направивме неколку случајни разбивања на комплетното множество обележја во различни соодноси на структурните и статистичките обележја.

Беа направени десет парови на случајни разбивања на множеството обележја со спојување на 25 случајно избрани обележја од структурното множество и 29 случајно избрани обележја од статистичкото множество формирајќи мешано множество од 54 обележја. Останатите 29 обележја од структурното множество и останатите 33 обележја од статистичкото множество беа споени во второто множество со 62 обележја. Со ваквото разбивање и спојување на деловите на структурното и статистичкото

recognition rates using various statistical cooperation schemes are presented. We have used the same rejection criterion as in Table 1, and suitable values for T_1 and T_2 were chosen in order to achieve reliability of at least 99%.

The decision fusion methods: Product, Dempster Rule, Fuzzy Integral, and Decision Templates require possibilistic outputs. To map the original output values to $[0, 1]$ interval we used the mapping $1/(1+e^x)$.

In order to make the final decision, first four cooperation schemes use the maximum of the sum, the maximum of the product, the maximum of the maximum and the maximum of the minimum of the corresponding pairs of the classifier outputs [12]. The Dempster rule considers the fuzziness of the classifier votes by giving less confidence to less certain votes [13]. The naive Bayes cooperation scheme uses the confusion matrices of member classifiers to estimate the certainty of the classifier decisions [13]. The Borda count cooperation method is a generalization of the majority vote [14]. The fuzzy integration is based on searching for the maximal grade of agreement between the objective evidence (provided by the sorted classifier outputs for specific class) and the expectation (the fuzzy measure values of both classifiers) [15]. We have also used several decision template approaches described elsewhere [16]. The dynamic average approach uses dynamic weights that are adjusted to be proportional to the certainties of the respective classifier outputs rather than globally chosen weights as in generalized committee [17]. The generalized committee prediction is based on a weighted sum of the predictions of the member classifiers [18]. The modified generalized committee differs from the generalized committee only by the chosen weights that are different for every class output. In other words, we used a vector of adjusted weights rather than one common weight per classifier.

A few results in Table 2 deserve attention. The best recognition rates (Recog. > 97.70%) are obtained by five of the cooperation schemes. Let us note that these results are almost identical to the recognition rate of the SVM that uses both feature families as one feature set (see Table 1).

On the other hand, the best recognition rates with reliability of 99% are provided by the schemes 21 (Generalized Committee) and 2 (Product). These results are noticeably better than the corresponding results shown in Table 1. Generally speaking, the classifier cooperation schemes with rejection criteria offer improved recognition rates in comparison to the classifier that utilizes the both feature families in one feature set.

4.2 Decision Fusion on Random Partitions of the Feature Set

To examine usefulness of grouping features according to their "nature" we performed a few random partitioning of the complete feature set in different relations between structural and statistical features.

Ten pairs of random feature subsets were created by combining 25 randomly chosen features from the structural feature set and 29 randomly chosen features from the statistical feature set to form a mixed feature set containing 54 features. The remaining 29 features from the structural fea-

Табела 2. Различни статистички шеми на комбинирање и нивните нивоа на препознавање
 Table 2. Various statistical cooperation schemes and corresponding recognition rates

| # | Шеми на комбинирање / Cooperation schemes | Преп. (%) Recog. (%) | T_1, T_2 | ДПреп. (%) RRecog. (%) | Погр. (%) MiscI. (%) | Отфр. (%) Reject. (%) | Довер. (%) Reliab. (%) |
|-----|---|----------------------------|--------------|------------------------------|-------------------------|-----------------------------|---------------------------|
| 1. | Просек / Average | 97.70 | 0.453, 0.140 | 95.34 | 0.96 | 3.70 | 99.00 |
| 2. | Производ / Product | 97.73 | 0.376, 0.039 | 95.39 | 0.96 | 3.65 | 99.01 |
| 3. | Макс-Макс / Max-Max | 97.09 | 0.590, 0.197 | 93.51 | 0.92 | 5.57 | 99.02 |
| 4. | Мин-Макс / Min-Max | 97.23 | 0.322, 0.122 | 94.80 | 0.92 | 4.27 | 99.03 |
| 5. | Борда пребројување / Borda count | 97.70 | 0.907, 0.281 | 95.34 | 0.96 | 3.70 | 99.00 |
| 6. | Наивен Бајесов / Naive Bayes | 97.24 | 0.919, 0.860 | 93.98 | 0.92 | 5.10 | 99.03 |
| 7. | Демпстер / Dempster | 97.78 | 0.217, 0.081 | 94.82 | 0.94 | 4.24 | 99.02 |
| 8. | Неодреден интеграл / Fuzzy Integral | 97.09 | 0.590, 0.197 | 93.51 | 0.92 | 5.57 | 99.02 |
| 9. | Одлучувачки шаблони П1 / Decision Templates P1 | 97.66 | 0.518, 0.097 | 94.57 | 0.94 | 4.49 | 99.01 |
| 10. | Одлучувачки шаблони П2 / Decision Templates P2 | 97.68 | 0.857, 0.033 | 94.90 | 0.92 | 4.17 | 99.03 |
| 11. | Одлучувачки шаблони П3 / Decision Templates P3 | 97.61 | 0.805, 0.030 | 95.06 | 0.94 | 4.00 | 99.02 |
| 12. | Одлучувачки шаблони П4 / Decision Templates P4 | 97.56 | 0.497, 0.107 | 94.82 | 0.92 | 4.25 | 99.03 |
| 13. | Одлучувачки шаблони И1 / Decision Templates I1 | 97.66 | 0.645, 0.097 | 95.19 | 0.96 | 3.85 | 99.00 |
| 14. | Одлучувачки шаблони И2 / Decision Templates I2 | 97.60 | 0.932, 0.016 | 94.38 | 0.92 | 4.69 | 99.03 |
| 15. | Одлучувачки шаблони И3 / Decision Templates I3 | 97.56 | 0.827, 0.015 | 94.94 | 0.94 | 4.12 | 99.02 |
| 16. | Одлучувачки шаблони И4 / Decision Templates I4 | 96.99 | 0.489, 0.183 | 93.53 | 0.92 | 5.55 | 99.02 |
| 17. | Одлучувачки шаблони И5 / Decision Templates I5 | 97.09 | 0.352, 0.216 | 93.02 | 0.91 | 6.07 | 99.03 |
| 18. | Одлучувачки шаблони Ц / Decision Templates C | 97.12 | 0.577, 0.195 | 93.58 | 0.92 | 5.50 | 99.02 |
| 19. | Одлучувачки шаблони Е / Decision Templates E | 97.71 | 0.967, 0.022 | 95.16 | 0.94 | 3.90 | 99.02 |
| 20. | Динамичен просек / Dynamic average | 97.70 | 0.204, 0.083 | 95.24 | 0.94 | 3.82 | 99.02 |
| 21. | Обопштен комитет / Generalized Committee | 97.73 | 0.221, 0.073 | 95.41 | 0.94 | 3.65 | 99.02 |
| 22. | Мод. обопштен комитет / Modified Generalized Committee | 97.76 | 0.216, 0.074 | 95.27 | 0.94 | 3.78 | 99.02 |

множество обележја ние добивме множества со ист број обележја како оригиналните множества на структурни и статистички обележја. Новодобиените множества содржат обележја од двете фамилии во однос што соодветствува на оригиналните структурни и статистички множества $25:29 \approx 29:33 \approx 54:62$. Со ваквите разбивања ние сме во можност да го користиме истиот систем на препознавање за правење на експериментите, т.е. да ги одбегнеме повеќето од резултатските пореметувања што можат да се случат поради променетиот систем.

ture set and the remaining 33 features from the statistical feature set were combined in another feature set containing 62 features. By partitioning and joining the parts of the structural and statistical feature sets this way, we have obtained two feature sets with the same number of features as the original structural and statistical feature sets. The new feature subsets contain features from both feature families in relations that correspond to structural and statistical feature families $25:29 \approx 29:33 \approx 54:62$. By this partitioning we were able to use the same system to conduct the experiments, i.e. to avoid most of disturbances that could be implied by the altered system.

За секој пар од мешаните множества обележја беше трениран пар на МНВ класификатори. Излезите од секој пар МНВ класификатори беа комбинирани со истите шеми на комбинирање дадени во табелата 2. Во табелата 3, се дадени просечните нивоа на препознавање за десетте случајни разбивања на не комплетното множество обележја.

For each pair of obtained feature subsets a pair of SVM classifiers was trained to perform classification over a single mixed feature set. The outputs of each pair of classifiers were combined using the same classifier cooperation schemes given in Table 2. In Table 3, average recognition rates over the ten random partitioning of the feature set are presented.

Табела 3. Просечни нивоа на препознавање на шемите на комбинирање за 10 случајни разбивања на множеството обележја

Table 3. Average recognition rates of cooperation schemes on 10 random partitioning of the feature set

| # | Шеми на комбинирање / Cooperation schemes | Преп. (%) Recog. (%) | T ₁ , T ₂ RRecog. (%) | ДПреп. (%) Miscl. (%) | Погр. (%) Reject. (%) | Отфр. (%) Reliab. (%) |
|-----|---|-------------------------|--|-----------------------------|-----------------------------|-----------------------------|
| | Множество 1 (54 обележја) / Set 1 (54 features) | 96.02 ($\sigma=0.25$) | 89.20 ($\sigma=1.37$) | 0.89 | 9.91 | 99.00 |
| | Множество 2 (62 обележја) / Set 2 (62 features) | 96.67 ($\sigma=0.18$) | 91.89 ($\sigma=0.98$) | 0.91 | 7.20 | 99.00 |
| 1. | Просек / Average | 97.67 ($\sigma=0.10$) | 95.32 ($\sigma=0.37$) | 0.94 | 3.74 | 99.00 |
| 2. | Производ / Product | 97.69 ($\sigma=0.10$) | 95.31 ($\sigma=0.35$) | 0.95 | 3.75 | 99.01 |
| 3. | Макс-Макс / Max-Max | 97.38 ($\sigma=0.09$) | 94.51 ($\sigma=0.62$) | 0.93 | 4.56 | 99.02 |
| 4. | Мин-Макс / Min-Max | 97.36 ($\sigma=0.14$) | 94.45 ($\sigma=0.42$) | 0.94 | 4.61 | 99.03 |
| 5. | Борда пребројување / Borda count | 97.67 ($\sigma=0.10$) | 95.32 ($\sigma=0.37$) | 0.94 | 3.74 | 99.00 |
| 6. | Наивен Бајесов / Naive Bayes | 97.24 ($\sigma=0.12$) | 74.60 ($\sigma=15.15$) | 0.65 | 24.75 | 99.03 |
| 7. | Демпстер / Dempster | 97.63 ($\sigma=0.10$) | 95.10 ($\sigma=0.45$) | 0.94 | 3.96 | 99.02 |
| 8. | Неодреден интеграл / Fuzzy Integral | 97.38 ($\sigma=0.09$) | 94.51 ($\sigma=0.62$) | 0.93 | 4.56 | 99.02 |
| 9. | Одлучувачки шаблони П1 / Decision Templates P1 | 97.61 ($\sigma=0.08$) | 95.10 ($\sigma=0.35$) | 0.94 | 3.96 | 99.01 |
| 10. | Одлучувачки шаблони П2 / Decision Templates P2 | 97.63 ($\sigma=0.07$) | 95.09 ($\sigma=0.34$) | 0.94 | 3.97 | 99.03 |
| 11. | Одлучувачки шаблони П3 / Decision Templates P3 | 97.66 ($\sigma=0.08$) | 95.24 ($\sigma=0.41$) | 0.94 | 3.83 | 99.02 |
| 12. | Одлучувачки шаблони П4 / Decision Templates P4 | 97.43 ($\sigma=0.10$) | 94.58 ($\sigma=0.54$) | 0.94 | 4.49 | 99.03 |
| 13. | Одлучувачки шаблони И1 / Decision Templates I1 | 97.60 ($\sigma=0.08$) | 95.07 ($\sigma=0.32$) | 0.93 | 4.00 | 99.00 |
| 14. | Одлучувачки шаблони И2 / Decision Templates I2 | 97.57 ($\sigma=0.09$) | 94.96 ($\sigma=0.45$) | 0.94 | 4.10 | 99.03 |
| 15. | Одлучувачки шаблони И3 / Decision Templates I3 | 97.64 ($\sigma=0.11$) | 95.21 ($\sigma=0.40$) | 0.94 | 3.85 | 99.02 |
| 16. | Одлучувачки шаблони И4 / Decision Templates I4 | 97.13 ($\sigma=0.12$) | 94.20 ($\sigma=0.60$) | 0.93 | 4.88 | 99.02 |
| 17. | Одлучувачки шаблони И5 / Decision Templates I5 | 97.38 ($\sigma=0.09$) | 94.45 ($\sigma=0.62$) | 0.93 | 4.63 | 99.03 |
| 18. | Одлучувачки шаблони Ц / Decision Templates C | 97.37 ($\sigma=0.10$) | 94.44 ($\sigma=0.62$) | 0.93 | 4.63 | 99.02 |
| 19. | Одлучувачки шаблони Е / Decision Templates E | 97.63 ($\sigma=0.10$) | 95.21 ($\sigma=0.31$) | 0.94 | 3.86 | 99.02 |
| 20. | Динамичен просек / Dynamic average | 97.65 ($\sigma=0.10$) | 95.30 ($\sigma=0.35$) | 0.95 | 3.75 | 99.02 |
| 21. | Обопштен комитет / Generalized Committee | 97.75 ($\sigma=0.07$) | 95.34 ($\sigma=0.31$) | 0.94 | 3.72 | 99.02 |
| 22. | Мод. обопштен комитет / Modified Generalized Committee | 97.82 ($\sigma=0.12$) | 95.34 ($\sigma=0.38$) | 0.94 | 3.72 | 99.02 |

Добиените резултати покажуваат дека мешањето на обележјата од "послабото" структурно и "појакото" статистичко множество доведува до поизедначени нивоа на препознавање со 0.65% просечна разлика и 2.69% просечна разлика кога се користи критериум за отфрлање за доверливост од 99%. Благата предност на множеството од 62 обележја е очекувана бидејќи нивниот број позитивно влијае на нивоата на препознавање.

Нивоата на препознавање добиени со случајните разбивања на комплетното множество обележја (види ја табелата 3) не се полоши, но не се и подобри од оние добиени со разбивањето на множеството обележја според нивната природа на структурни и статистички (види ја табелата 2). Да забележиме дека пет нивоа на препознавање од табелата 2 надминуваат 97.70%, додека во табелата 3 такви има само два. Од друга страна, најдоброто ниво на препознавање доаѓа од модификуваниот Обопштен комитет од табелата 3 (97.82%). Со користењето на критериумите за отфрлање во шемите на комбинирање ситуацијата е слична, но во спротивна насока. Тука во табелата 2 имаме четири нивоа на препознавање над 95.30%, додека во табелата 3 имаме такви шест. Најдоброт резултат е добиен со Обопштен комитет од табелата 2 (95.41%).

5. ЗАКЛУЧОК

Во овој труд се разгледани некои битни моменти во креирањето на систем со висока доверливост за препознавање со рака испишани цифри што користи комбинирање на МНВ класификатори. За таа цел беа користени две фамилии обележја наречени структурни и статистички. Спојувањето на одлуките на класификаторите е направено со статистички шемите на комбинирање. За подобрување на доверливоста на системот беа воведени критериуми за отфрлање на недоволно сигурните класификации.

Дадените резултати покажуваат дека е тешко да се достигне нивото на препознавање на еден класификатор што го користи целото множество обележја со комбинирање на одлуките на индивидуалните класификатори креирани посебно за структурното и статистичкото множество обележја. Сепак, комбинирањето на класификатори ја намалува комплексноста на системот, може благо да го подобри нивото на препознавање и овозможува подобра трговија меѓу нивото на препознавање и доверливоста на системот. Дополнително, ние ги споредувавме комбинирањата на класификаторите креирани врз различни разбивања на множеството обележја вклучувајќи случајни разбивања како и разбивање врз база на "природата" на обележјата. Овие резултати покажаа дека "природното" разбивање на множеството обележја не е секогаш најдобар начин да се креира систем за препознавање врз база на комбинирање на класификатори.

The obtained results show that mixing the features from the "weaker" structural and "stronger" statistical feature set provides more comparable classifier performances with 0.65% average difference in recognition rate and 2.69% average difference when rejection criteria is used. The slight advantage of the feature set that contains 62 features is expected, because of the larger number of features used to represent the sample.

The recognition results obtained by random partitioning of the feature set (Table 3) are not worse, but also not better than the recognition results obtained by partitioning of the feature set according to the feature nature (Table 2). Let us note that in Table 2 five recognition rates exceeds 97.70%, while in Table 3 there are only two. On the other hand, the best recognition rate comes from the modified generalized committee in Table 3 (97.82%). By applying rejection criteria in the cooperation schemes, the situation is quite similar in opposite way. Now, in Table 2 we have six recognition rates over 95.30%, while there are four in Table 3. The best result is obtained by the generalized committee in Table 2 (95.41%).

5. CONCLUSION

In this paper, we address some issues in designing high reliability system for hand-written digit recognition using cooperation of SVM classifiers. We used two different feature families referenced as structural and statistical features. Decision level fusion is performed using statistical cooperation schemes applied on classifiers designed individually for both feature families. To improve the system reliability, we introduced rejection criteria in decision fusion schemes.

The presented results show that it is difficult to achieve the recognition rate of single classifier applied on the complete feature set by statistical decision fusion applied on the individual classifier outputs. However, classifier cooperation schemes reduce classifier complexity, slightly improve recognition rates and enable fine tuning of the recognition versus the reliability tradeoff. Additionally, we compare decision fusions of the classifiers designed for different partitioning of the feature set including random partitioning and partitioning by feature nature and show that "natural" partitioning of the feature set according to feature nature is not always the best way to apply classifier decision fusion.

ЛИТЕРАТУРА / REFERENCES

1. F. Kimura, M. Shridar: Handwritten Numerical Recognition Based on Multiple Algorithms, *Pattern Recognition*, Vol. 24, No. 10, 1991, pp. 969–983.
2. Y. S. Huang, C. Y. Suen: A Method of Combining Multiple Classifiers – A Neural Network Approach. *Proc. 12th Int. Conf. Pattern Recognition and Computer Vision*, Jerusalem, 1994, pp. 473–475.
3. T. Suzuki, H. Nishida, Y. Nakajima, H. Yamagata, M. Tachikawa, G. Sato: A Handwritten Character Recognition System by Efficient Combination of Multiple Classifiers, *Int. Association for Pattern Recognition Workshop on Document Analysis Systems*, World Scientific, Singapore, 1995, pp. 169–187.
4. S. Yamaguchi, T. Tsutsumida, F. Kimura, A. Iwata: Study on Multi-Expert Systems for Handprinted Numeral Recognition, In: Downton, A.C., Impedovo, S. (eds.): *Progress in Handwriting Recognition*. World Scientific, Singapore, 1997, pp. 285–292.
5. J. Dahmen, D. Keysers, H. Ney: Combined Classification of Handwritten Digits Using the 'Virtual Test Sample Method'. In: Kittler, J., Roli, F. (eds.): Multiple Classifier Systems, 2nd Int. Workshop, MCS 2001 Cambridge, UK, *Lecture Notes in Computer Science Vol. 2096*, Springer-Verlag, 2001, pp. 109–118.
6. C. Burges: A Tutorial on Support Vector Machines for Pattern Recognition, *Knowledge Discovery and Data Mining*, Vol. 2, 1998, pp. 1–47.
7. V. Radevski, Y. Bennani: Reliability Control in Committee Classifier Environment, *Int. Joint Conference on Neural Networks, IJCNN 11*, Como, Italy, Vol. III., 2000, pp. 561–565.
8. Y. LeCun, L. D. Jackel, L. Bottou, A. Brunot, C. Cortes, J. S. Denker, H. Drucker, I. Guyon, U. A. Muller, E. Sackinger, P. Simard, V. Vapnik: Comparison of Learning Algorithms for Handwritten Digit Recognition. In: Fogelman, F., Gallinari, P. (eds.): *Int. Conf. Artificial Neural Networks*, Paris, 1995, pp. 53–60.
9. D. Cakmakov: Curve Matching Using Turning Functions. *Proc. of the Int. Conf. on Signal and Image Processing SIP'98*, Las Vegas, 1998, pp. 588–592.
10. G. Burel, I. Pottier, J. Y. Catros: Recognition of Handwritten Digits by Image Processing and Neural Network, *Proc. Of the Int. Joint Conf. on Neural Networks, IJCNN 3*, 1992, pp. 666–671.
11. R. Collobert, S. Bengio, and J. Mariéthoz. Torch: a modular machine learning software library. Technical Report IDIAP-RR 02–46, IDIAP, 2002.
12. J. Kittler, M. Hatef, R. P. W. Duin, J. Matas: On Combining Classifiers, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 20, No. 3, 1998, pp. 226–239.
13. L. Xu, A. Krzyzak, C. Y. Suen: Methods of combining multiple classifiers and their application to handwritten recognition, *IEEE Transactions on System, Man and Cybernetics*, Vol. 22, 1992, pp. 418–435.
14. T. K. Ho, J. J. Hull, S. N. Srihari: Decision Combination in Multiple Classifier Systems, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 16, No. 1, 1994, pp. 66–75.
15. S. B. Cho, J. H. Kim: Combining Multiple Neural Networks by Fuzzy Integral and Robust Classification, *IEEE Transactions on System, Man and Cybernetics*, Vol. 20, No. 3, 1995, pp. 380–384.
16. L. I. Kuncheva, J. C. Bezdek, P. W. Duin: Decision Templates for Multiple Classifier Fusion: An Experimental Comparison, *Pattern Recognition*, Vol. 34, No. 2, 2001, pp. 299–314.
17. A. D. Jimenez, N. Walsh: Dynamically weighted ensemble neural networks for classification, Proceedings of the 1998 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK 1998.
18. C. M. Bishop, *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford, 1995, pp. 364–369.