

## Синтез на класификатори по цветови признаци за откриване на плесени от рода *Fusarium Moniliforme* по царевични зърна

Елеонора Кирилова

**Classifier Design for identification of corn kernels, damaged by *Fusarium Moniliforme*, using color features:** *This paper presents various stages involved in the design of a classification system for identification of *Fusarium* damaged corn kernels. Firstly some techniques for selection of subsets of color features are discussed and tested. Those, which are rich in discriminatory information with respect to the classification problem, are selected and after that different classifiers (including k-NN, SVM and Decision tree) are employed in the selected feature spaces. The classifier performance is estimated and the results showed that the highest accuracy of 87.5 + 99.17% is achieved by the Decision tree model.*

**Key words:** *Classifier design, k-nearest neighbor, SVM, Feature selection, Color features, Corn kernels.*

### ВЪВЕДЕНИЕ

Частен случай на задачата за разпознаване на образи е класификацията на обекти по принадлежността им към определени групи (класове). Класификацията е информационен процес и се състои в преобразуване на информацията за стойностите на признаците, описващи обектите за класифициране, в информация за принадлежността им към предварително определен клас [4]. При избора на адекватен класификатор основните критерии, които се съблюдават са приложимост, ефективност и време за класификация, при достатъчно висока точност на класификацията. Ефективността на различните класификатори зависи съществено от статистическите характеристики на входните данни използвани за формиране на класификатора, т.е. от обучаващата извадка и от априорната информация [1,3].

Синтезът на признаци за разпознаване и изборът на комплекс от най-информативни признаци са едни от най-важните етапи при разработване на разпознаващ алгоритъм, за който в повечето практически задачи не съществува универсален подход. Посредством избора на най-значими/информативни признаци се цели визуализиране на класовете като добре разделими области в признаковото пространство. Друг аспект свързан с определяне значимостта на набора от признаци е определянето на най-добрата комбинация от признаци, състояща се от минимален брой признаци.

Тематиката за създаване на класификационни модели е обект на изследване от редица автори [4,5,6], в [7] е направен сравнителен анализ на няколко техники за подбор на признаци, използващи различни критерии – Information Gain - IG, Gain Ratio – GR, Chi-square - CS, Relief-F и ефективността на тези методи е оценена чрез точността от класификация с k-NN, Naïve Bayes, „дърво на решенията” и SVM класификатори.

Синтезът на класификационен модел е задача, чието решение е сторго зависимо от природата и характеристиките на обектите, подлежащи на анализ. Това е основната причина, поради която до настоящия момент не е намерена универсална и еднозначна методика за решение на класификационни задачи.

Имайки предвид изложеното дотук, основна цел на настоящият доклад е избор на оптималната класификационна стратегия за определяне качеството на земеделската продукция с цел разделянето ѝ в два класа: здрави царевични зърна и заразени царевични зърна (поразени от плесени от рода Розова Фузариоза).

### ИЗЛОЖЕНИЕ

Основни направления, които трябва да бъдат отчетени при синтеза на класификатори на аграрни продукти по качествени признаци, според литературния обзор по темата са: Формализация на описанието на обекта; Формиране на

обучаваща извадка; Обучение на класификатора; Намаляване размерността на признаковото пространство; Класификация; Определяне точността на класификация.

При формиране на изходното признаково пространство, от всеки пиксел от изображението на зърната се извличат по 17 цветови признака, съответстващи на 17-те компоненти (R, G, B, L, a, b, X, Y, Z, H, S, V, Y, Cb, Cr, x, y) от следните цветови модели: RGB, Lab, XYZ, HSV, YCbCr, xyY. Базата данни, която се използва при анализа съдържа средноаритметичните стойности на цветовете компоненти от всички пиксели в изображението на зърното:

$$\bar{R}_m = \frac{1}{n} \sum_{i=1}^n R_i, \quad (1)$$

където R е стойността на R компонентата от RGB цветовия модел; m е номер на зърното (m = 1, 2, ..., 150); i – номер на пиксел от изображението на зърното; n – брой на пикселите от изображението на зърното. Процедурите по извличане, преобразуване и анализ на цветовете признаци за изображенията са публикувани в [2] и няма да бъдат обект на настоящия доклад.

### 1. Критерии и методи, използвани за определяне диагностичната „ценност“ на признаците за класификация на здрави и заразени зърна

При решаването на задачата за намиране на оптималното минимално подмножество от признаци в настоящото изследване са използвани няколко критерия за определяне диагностичната ценност, както на всеки от признаците поотделно така и в комбинации.

#### 1.1. Критерии за индивидуално оценяване значимостта на признаци

➤ FDR (Fisher's Discriminant Ratio) – критерий за едномерна разделяемост по индивидуални признаци, между два равностойни класа обекти. Критерият е независим от типа на разпределенията в класовете. За признаците, за които средните стойности за двата класа обекти се различават много помежду си, а дисперсиите в класовете са малки по стойност, стойността на FDR критерия (2) ще бъде голяма и признакът ще е силно информативен.

$$FDR = \frac{(m_1 - m_2)^2}{(\sigma_1^2 + \sigma_2^2)} \quad (2)$$

Където  $m_1$  е средната стойност на даден признак за първия клас;  $m_2$  е средната стойност на признака за втория клас;  $\sigma_1^2$  е средноквадратичното отклонение на стойностите на признака в първия клас;  $\sigma_2^2$  е средноквадратичното отклонение на стойностите на признака във втория клас.

➤ Критерий хи квадрат (Chi-square/ CS) – CS измерва известната  $\chi^2$  статистика за всеки от входното подмножество признаци по отношение на класовете. Голямата стойност на  $\chi^2$  съответства на силна корелираност между признака и съответния клас.  $\chi^2$  за признака F се изчислява по следната зависимост:

$$\chi^2(F) = \sum_{i=1}^m \sum_{j=1}^k \frac{(A_{ij} - E_{ij})^2}{E_{ij}}, \quad E_{ij} = \frac{R_i \cdot C_j}{|S|}, \quad (3)$$

където m – брой на подгрупите формиращи от стойностите на признака F; k – брой на класовете;  $A_{ij}$  – стойността на признак в i-та подгрупа на j-ия клас;  $E_{ij}$  – очакваната

принадлежност на признака  $A_{ij}$  към  $i$ -та подгрупа;  $C_j$  - брой на признаците в  $j$ -ия клас;  $R_i$  - броя на наблюденията в  $i$ -та подгрупа.

1.2. Критерии за оценяване значимостта на комбинации от признаци (т.нар. вектор на признаците – *feature vectors*) и оценяване на разделимостта на класовете в съответното признаково пространство

➤ Критерий  $J_3$  основаващ се на Диаграми на разсейването (*Scatter matrices*)

$$J_3 = \text{trace}\{S_w^{-1}S_b\},$$

където  $S_w$  е вътрекласовата, а  $S_b$  – междукласовата ковариационни матрици.

1.3. *Feature Subset Selection* – Опирайки се на резултатите получени от индивидуалните оценки за значимост на признаците (по критерия FDR) се редуцира броят на признаците с които се работи по нататък. За получаването на оптимална комбинация от информативни признаци, за която дискриминантната мощ за разделяне на класовете е най-силна е необходимо да се приложи още методика за оценка на всички възможни комбинации от признаци, като се отчита и коефициента на взаимна корелацията между признаците (*cross-correlation coefficient*).

➤ *Scalar Feature Selection* – Процедурата изчислява коефициента на взаимна корелацията между първия (най-значим) признак и всеки следващ признак.

➤ Дискриминантен анализ (*General Discriminant Analysis*) – Представява концепция за избор на подходящия набор от количествени променливи, с които да се построи класификационен модел. Съгласно концепцията на Фишер, един дискриминантен анализ ще бъде толкова по-добър, колкото е по-малко частното на двете детерминанти:  $Wilk' s\Lambda = \det W / \det T$ , където  $W$  е вътрешногрупова ковариационна матрица, а  $T$  е общата ковариационна матрица. Критерият още се нарича критерий на Уилкс или  $\lambda$  - критерий.

Таблица1. Резултати от процедурите за избор на комбинации от информативни признаци


Сорт	Страна на зърното	General Discriminant Analysis GDA (Wilk's Lambda)	Scalar Feature Ranking (FDR+ $J_3$ )	Best feature combination (3 features)
Кнежа 308	гладка	G,H,S,V,L,a,b,X,Ycbcr,cb,cr,xm,ym	B,S,b,Z,cb,xm,ym	B,S,Z
	зародиш	G,H,S,V,L,a,b,X,Ycbcr,cb,cr,xm,ym	B,S,b,Z,cb,xm,ym	B,S,Z
	общо	G,H,S,V,L,a,b,Y,Ycbcr,xm,ym	B,S,b,Z,cb,xm,ym	B,S,Z
Кнежа 436	гладка	B,H,S,V,L,a,b,Y,Ycbcr,cb,cr,xm,ym	B,S,b,cb,cr,xmym	B,b,cb
	зародиш	B,H,S,V,L,a,b,Y,Ycbcr,cb,cr,xm,ym	B,S,b,Z,cb,xm,ym	B,b,Z
	общо	B,H,S,V,L,a,b,Z,cb,xm,ym	B,S,b,Z,cb,xm,ym	B,b,Z
Кнежа 446	гладка	G,H,S,V,L,a,b,Y,Ycbcr,cr,xm,ym	B,H,L,Y,Ycbcr,cr,xm	H,Y,cr
	зародиш	G,H,S,V,L,a,b,X,Ycbcr,cr,xm,ym	B,S,a,b,Z,cb,ym	B,V,cb
	общо	G,H,S,V,L,a,b,Y,Ycbcr,xm,ym	B,H,V,a,X,Z,ym	V,X,Z
Кнежа 613	гладка	B,H,S,V,L,a,b,Z,Ycbcr,xm,ym	B,S,b,cb,cr,xm,ym	S,xm,ym
	зародиш	H,S,V,L,a,b,Y,Ycbcr,cr,xm,ym	H,S,a,b,cb,cr,xmym	H,S,b
	общо	B,H,S,V,L,a,b,Z,cb,xm,ym	G,H,S,b,cb,xmym	G,S,b
Кнежа 620	гладка	B,H,S,V,L,a,b,Z,cb,xm,ym	B,H,S,b,cb,xm,ym	H,S,ym
	зародиш	B,H,S,V,L,a,b,Z,cb,xm,ym	H,S,a,b,cb,xm,ym	H,S,b
	общо	B,H,S,V,L,a,b,Z,cb,xm,ym	H,S,b,X,Y,cb,xm,ym	H,X,cb
ХМ 87/136	гладка	B,H,S,V,L,a,b,Z,cb,xm,ym	R,V,L,b,Y,cb,ym	b,Y,ym
	зародиш	B,H,S,V,L,a,b,Z,cb,xm,ym	G,L,a,b,Y,cb,ym	G,L,ym
	общо	B,H,S,V,L,a,b,Z,cb,xm,ym	G,L,a,b,Y,cb,ym	b,Y,ym
Русе 424	гладка	G,H,S,V,L,a,b,Y,Ycbcr,xm,ym	B,S,b,X,cb,xm,ym	B,S,ym
	зародиш	G,B,H,S,V,L,a,b,Z,xm,ym	G,S,L,b,cb,xm,ym	G,S,L
	общо	H,S,V,L,a,b,X,Ycbcr,cr,xm,ym	S,L,b,Y,Ycbcr,cb,ym	L,Y,ym
26A	гладка	B,H,S,V,L,a,b,Z,cr,xm,ym	B,H,S,b,Z,xm,ym	B,b,ym
	зародиш	H,S,V,L,a,b,Z,Ycbcr,cb,xm,ym	B,H,V,b,Z,xm,ym	H,V,ym
	общо	G,H,S,V,L,a,b,Y,Ycbcr,xm,ym	B,H,S,V,b,Z,ym	B,b,ym

Програмните инструменти които са използвани при реализиране на анализите са Интерактивна програмна среда MATLAB 7.1 и STATISTICA 8.0 (StatSoft, Inc.) В таблица 1. са показани получените комбинации от информативни признаци за 8 сорта царевични зърна и 3 групи от данни – за изображения на зърна заснети само от „гладка“ страна, за такива заснети от страна „зародиш“ и за смесени бази данни, като са използвани съответно три критерия (т.1). Критериите *Scalar Feature Ranking* и *Best feature combination* използват бази данни с нормирани стойности на признаците, а при методът *GDA(General Discriminant Analysis)* стойностите на признаците са необработени и съответстват на стойностите за компонентите на различните цветови модели. При методът *GDA* общия брой на тестваните комбинации с признаци за всяка подизвадка от всеки сорт е 131 069, този брой зависи изцяло от броя на признаците в изходното подмножество, в случая 17 признака.

## 2. Сравнителен анализ на стандартни методи за класификация. Резултати от класификация с подобрите комбинации от информативни признаци.

Разгледани са особеностите и характеристиките на три типа класификатори и е направено сравнително изследване при решаване на задачата, свързана с разпознаване на изображения на здрави и заразени с Фузариоза царевични зърна.

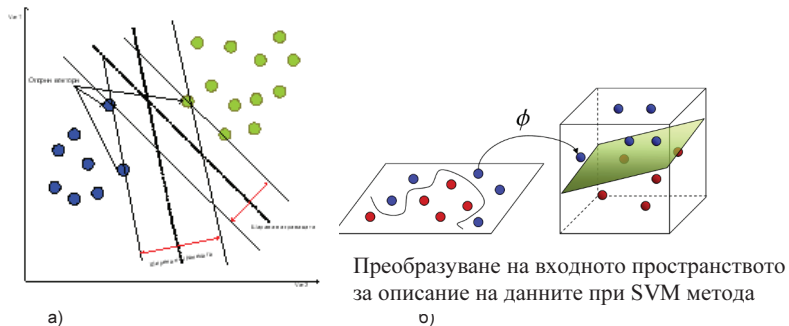
➤ *k*-NN класификатор - непараметричен класификатор, който работи на принципа класификация чрез асоциация към група от образи от даден клас, наречени най-близки съседи. Всеки клас се представя като съвкупност от множество еталони. Неизвестният образ се отнася към даден клас, към който принадлежат поне  $S$  от най-близките съседи от обучаващата извадка от образи.  $S$  е праг за достоверност и обикновено се избира в границите :  $k/2 < S \leq k$ . Мярката за сходство/близост е избираема, като най-често това е евклидовото разстояние.



Фиг.1. Класификационен модел *k*-най-близки съседи

Ако сред отделените *k* образа от извадката, броят на образите, принадлежащи към един и същ клас е равен или по-голям от  $S$ , се приема, че обектът принадлежи към този клас. Ако това условие е изпълнено за два или повече класа, неизвестният образ се отнася към класа с най-голям брой най-близки съседи. *k* е цяло число, което нормално има малка стойност. Броят на най-близките съседи, до които се пресмята евклидовото разстояние се уточнява експериментално (фиг.1.).

➤ Метод на опорните вектори или още SVM класификатор (Support Vector Machines) – осъществява нелинейно преобразуване на оригиналните данни в друго пространство с по-висока размерност, където обектите са линейно разделими (фиг.1.б) [2]. При SVM - метода по т.нар. опорните точки, които представляват гранични точки за даден клас данни в многомерното пространство на признаците, могат да се изчислят хиперповърхнини разделящи класовете, за които дистанцията между границите за двата класа да е максимална (фиг.2.а).




Фиг.2. Оптимален хиперплан при SVM метода. а) при линейно разделими области; б) при нелинейно разделими области

Според типа на избраната кернъл функция  $\Phi$ , се конструират няколко типа класификатори (линеен, RBF, полиномиален, невронна мрежа MLP) [7,8]. В случая е избрана кернъл функция тип RBF (Radial Basis Function) с ширина  $\sigma$  (0,625), тя има следния вид:

$$K(x, y) = \exp(-\|x - y\|^2 / (2\sigma^2)) \quad (4)$$

➤ Класификационен модел Дърво на решенията - *Decision Trees*



Фиг.3. Класификационен модел „Дърво на решенията“

Дървото на решенията определя последователност - набор от логически *if-then* условия, по които се извежда класификационен модел въз основа на статистическите оценки и разпределения на наличните признаци. Предимства на метода "дърво на решенията" *Decision Trees*:

- Интерпретацията на резултатите, получени по този метод е изключително лесна (вместо линейни уравнения се получава набор от условия от вида *if-then*)
- Често класификационния модел които се построява по този метод е значително по-прост, но не по-малко ефективен
- Методът е непараметричен и нелинеен
- Няма предварителни условия за наличие на линейна връзка между предсказващите променливи и зависимите променливи.

За да се анализира пригодността на получените комбинации от признаци, те са приложени в два вида класификатори, единият работещ по метода на „к- най-близки съседа“, а другия по метода на опорните вектори. Получените резултати за точността на класификация са сравнени с още един, референтен, метод - „Дърво на решенията“.

Резултати от класификация и валидиране

Тъй като основната цел в настоящото изследване е изборът на оптимален вариант на класификатор от няколко алтернативи е приложен Метод за Крос/кръстосано-валидиране (Cross validation) или още Крос-валидация, чиято цел е настройване на моделите на класовете и след това за оценка на точността с която създадените модели ще се предстват в конкретната класификационна задача. При този метод за валидиране се задава процентното разпределение на образците за двете извадки и наличните данни за класовете се разделят по случаен начин на набор от двойки обучаващи и тестваци (валидиращи) извадки. За всяка от тези двойки се извършва обучение и тестване на класификатора, след това се изчислява общата средна точност за всички двойки извадки, което представлява резултатът от валидирането.

Поради природата и характеристиките на царевичните зърна е необходимо да бъде отчетено влиянието на страната на заснемане на зърната – гладка или зародиш и фактът, че цветовете характеристики на областта на зародиша в изображенията на зърната се доближават до тези на налепа образуван под влияние на плесените от типа *Fusarium Moniliforme*. При отчитане на тези фактори е определен размер на тестовите извадки за класификацията на подгрупите зърна. Съответно при класификация на групите „само гладка“, „само зародиш“ броят на зърната в отделните подизвадки съответно за сортове Кнежа 308, 436, 446, 613, 620 и 26 А е: 135 (Обучаваща), 45 (тестова), 150 (общо), а при класификация на групите „общо“, (включва изображения на двете страни) е - 450 (Обучаваща), 150 (тестова), 600 (общо); за сорт Русе 424 - 135 (Обучаваща), 45 (тестова), 180 (общо); за сорт ХМ87/136 - 90 (Обучаваща), 30 (тестова), 120 (общо).

Таблица 2. Точност на крос-валидация с k-пн и SVM класификатори

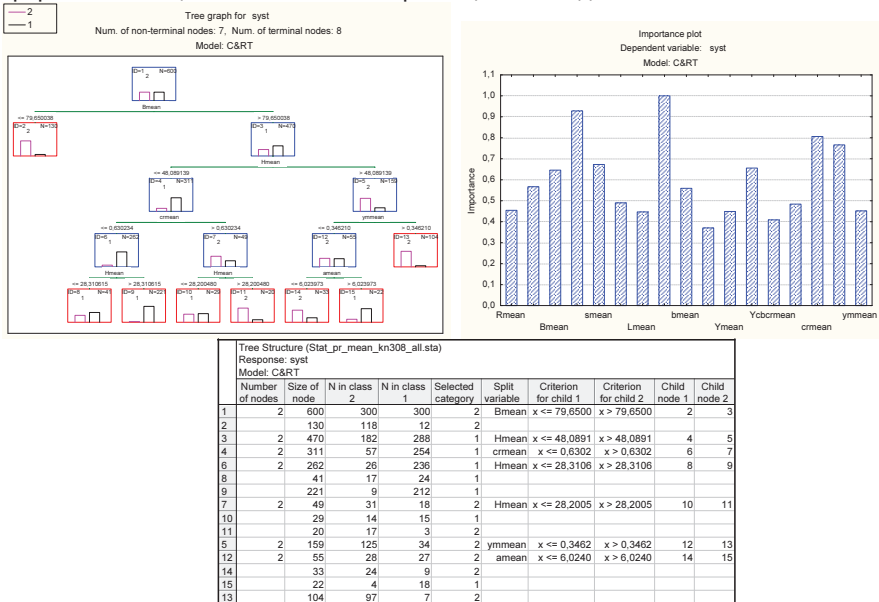
Сортове, реколта 2008 год.			Точност от крс валидация(Cross-validation accuracy),%			
			k-NN класификатор			SVM (тип RBF)
Сорт	Страна на заснемане	Всички цветови признаци	Признаци от GDA (Missclas. rate)	7 признака по FDR+J <sub>3</sub>	3 признака по FDR+J <sub>3</sub>	3 признака по FDR+J <sub>3</sub>
Кнежа 308	гладка	96,44(k=3)	96,44(k=5)	96,44(k=5)	96,44(k=5)	96,44
	зародиш	92,00 (k=4)	92,00(k=4)	92,44(k=5)	92,00(k=4)	92,89
	общо	74,67(k=5)	75,11(k=3)	70,00(k=2)	64,44 (k=4)	77,56
Кнежа 436	гладка	92,89 (k=5)	94,66(k=3)	93,77(k=3)	94,67(k=1)	95,11
	зародиш	94,67 (k=4)	95,11(k=4)	94,22(k=2)	92,00(k=1)	93,33
	общо	92,67(k=3)	94,22(k=3)	93,11(k=4)	91,78(k=4)	92,67
Кнежа 446	гладка	91,11 (k=2)	91,55(k=2)	92,00(k=2)	85,77(k=4)	88,44
	зародиш	95,56(k=3)	94,22(k=5)	95,11(k=3)	93,33(k=5)	92,89
	общо	91,77(k=3)	92,44(k=3)	93,11(k=3)	86,67(k=2)	89,78
Кнежа 613	гладка	97,33(k=5)	97,33(k=3)	98,67(k=3)	98,22(k=3)	99,11
	зародиш	93,77 (k=4)	94,67(k=3)	96,00(k=3)	96,00(k=3)	96,44
	общо	92,67(k=3)	93,33(k=5)	93,11(k=4)	88,44(k=5)	92,44
Кнежа 620	гладка	96,00(k=5)	95,11(k=4)	94,22(k=4)	94,22(k=3)	95,56
	зародиш	88,00(k=3)	88,89(k=4)	89,78(k=4)	90,66(k=3)	93,33
	общо	92,22(k=4)	92,22(k=4)	93,11(k=4)	92,44(k=4)	95,11
ХМ 87/136	гладка	91,11(k=3)	92,22(k=3)	91,11(k=3)	91,11(k=1)	92,22
	зародиш	86,67(k=2)	86,67(k=2)	86,67(k=4)	88,89(k=1)	87,78
	общо	83,89(k=4)	84,44(k=2)	85,00(k=2)	84,44(k=4)	86,11
Русе 424	гладка	99,25(k=5)	99,26(k=1)	98,52(k=1)	97,78(k=1)	99,26
	зародиш	98,52(k=4)	97,78(k=1)	97,78(k=2)	94,82(k=1)	94,07
	общо	97,41(k=3)	97,41(k=3)	97,04(k=3)	97,78(k=3)	98,52
26А	гладка	96,89(k=3)	96,44(k=3)	96,00(k=4)	96,44(k=3)	95,56
	зародиш	95,55(k=4)	96,00(k=4)	95,11(k=3)	96,89(k=4)	97,78
	общо	94,44(k=5)	94,67(k=4)	93,78(k=4)	92,44(k=4)	94,22

При синтезиране на k-NN класификаторите за всеки сорт оптималният брой на най-близките съседи “k” е избран експериментално (фиг.1). Избрана е такава

стойност на параметъра k, за която е получена най-високата точност на крос-валидация, като са тествани по 5 варианта, съответно за k=1,2,3,4 и 5.

Като оптимален класификатор се избира този модел и съответстващата му оптимална стойност на параметъра k, за който е получена минимална стойност на грешката от валидиране. От таблица 2. може да се направи изводът, че за повечето извадки точността постигната при класификация по методът на опорните вектори с по-малък брой признаци, е най-висока.

На фиг.4. е показано решението на класификатор по Методът „Дърво на решенията“ съответстващо на обединена извадка от данни за сорт Кнежа 308, като е избран критерий хи-квадрат съгласно формула (3). На фигурата могат да се видят генерираните решаващи условия, схематичното разпределение на образите в извадката в съответствие с решаващите условия, както и графика за информативната ценност на всеки от признаците за модела.



Фиг.4. Решение от класификатор „Дърво на решенията“ за данни от сорт Кнежа 308

В таблица 4. са обобщени резултатите от класификацията по Методът „Дърво на решенията“ за изображенията на зърната от общите извадки (гладка страна + зародиш) за всички изследвани сортове, класифицирани по метода Дърво на решенията“, като е направено е сравнение с точността постигната с k-pp класификатор. Точността, която е изчислена в таблица 3 представлява процента на правилно разпознати от класификатора примери относно всички примери и се пресмята по следната формула:

$$T = \frac{(TP + TN)}{(TP + TN + FP + FN)} \cdot 100, \% \quad (5)$$

където следните означения – TP, FP, TN, FN съответсват на етикетите, които могат да бъдат асоциирани от класификатора към един входен образец. Съответните значения на етикетите са следните: TP (True Positive) – действително правилен; TN (True Negative) – действително неправилен; FP (False Positive) – некоректен правилен; FN (False Negative) – некоректен неправилен.

Таблица 3. Точност на класификация с различни комбинации от информативни признаци

Сорт	Точност (Ассигуру) Т, %				
	k-NN класификатор				Метод „Дърво на решенията“
	Всички цветови признаци	Признаци от GDA	3 признака по FDR+J <sub>3</sub>	7 признака по FDR+J <sub>3</sub>	
Кнежа 308	80,00	79,33	70,00	80,00	87,5
Кнежа 436	92,00	92,00	90,00	91,33	95,00
Кнежа 446	90,67	91,33	84,67	91,33	92,33
Кнежа 613	96,67	96,67	98,00	98,00	95,66
Кнежа 620	89,33	89,33	90,67	89,33	94,17
ХМ 87/136	80,00	76,67	81,67	80,00	89,17
Русе 424	97,78	97,78	97,78	97,78	99,17
26А	96,00	95,33	93,33	94,00	95,33

### ЗАКЛЮЧЕНИЕ

В доклада се предлага сравнителен анализ на няколко критерия за определяне диагностичната ценност на всеки от признаците по-отделно както и в комбинации, като за вземане на окончателно решение по отношение на оптималния метод за класификация се отчита максималната точност постигната със стандартни методи. Установена е възможността за намаляване на броя на признаците. Практически той може да бъде редуциран, в зависимост от прилагания метод за разпознаване, до 3 признака при “Метод на опорните вектори”, 4-5 при метод „Дърво на решенията” или 9-11 при “к- най-близки съседа”, при запазване на сравнително близки стойности на класификационната точност. Показано е, че методът на опорните вектори позволява постигане на значително бързодействие и задоволителна точност при използване на по-малък брой признаци за окачествяване в сравнение с метода на “к-най-близки съседа”. Класификационния модел, построен по този метода „Дърво на решенията” е значително по-прост, но не по-малко ефективен, като постигнатата точност е най-висока при шест от сортовете (87.5 ÷ 99.17%).

### ЛИТЕРАТУРА

- [1] Дамянов Ч. Неразрушаващо разпознаване на качеството в системите за автоматично сортиране на хранителни продукти, АИ на УХТ -Пловдив, 2006
- [2] Кирилова Е., П. Даскалов, Р. Цонев, Ц. Драганова, Оценка влиянието на сортовата принадлежност върху цветови признаци за разпознаване на заболяването Фузариоза по царевични семена, чрез анализ на цветни изображения, Научни трудове на РУ, 2009, том 48 , серия 3.1, с. 144-149.
- [3] Младенов М., Анализ и оценка на качеството на зърно, Монография, Русе, 2011.
- [4] Шопов Н., Автоматични класификатори за неразрушаващо определяне качеството на картофени клубени, Дисертация, 2006, София.
- [5] Kavdir I., D.E.Guyer, Evaluation of different pattern recognition techniques for apple sorting, Biosystems Engineering 99, p.211-2129, 2008.
- [6] Pazoki A., Z. Pazoki, Classification system for rain fed wheat grain cultivars using artificial neural network, African Journal of Biotechnology Vol.10(41), p. 8031-8038, 2011.
- [7] Serkan G., O. N. Gerek et al., The search for optimal feature set in power event classification, Expert systems with applications, 2009.
- [8] Tsang C. et.al., Genetic-fuzzy rule mining approach and evaluation of feature selection techniques for anomaly intrusion detection, Pattern Recognition 40, p.2373-2391, 2007.

### За контакти:

Докторант инж. Елеонора Кирилова, Катедра “Автоматика и мехатроника”, РУ “Ангел Кънчев”, тел: 082/888 684, e-mail : [ekirilova@ru.acad.bg](mailto:ekirilova@ru.acad.bg)

Докладът е рецензиран.