

ОЦЕНКА НА СЪСТОЯНИЕТО НА ТЕХНИЧЕСКИ И ЕКОЛОГИЧНИ СИСТЕМИ С ИЗПОЛЗВАНЕ НА ТЕОРИЯТА ЗА РАЗПОЗНАВАНЕ НА ОБРАЗИ

ASSESSMENT OF TECHNICAL AND ENVIRONMENTAL SYSTEMS USING THEORY PATTERN RECOGNITION



ATANASOV Assen Nedev
e-mail: assenedev@gmail.com

ВВМУ „Никола Йонков Вапцаров“



ATANASOVA Pavlina Naskova
e-mail: pnaskova@abv.bg

Технически университет - Варна



ANDREEV Dimitar Bogomilov
e mail: andreev_b@abv.bg

ВВМУ „Никола Йонков Вапцаров“

В работата се изследват възможностите за създаване на обща алгоритмична основа за оценка на състоянието на широк кръг от обекти от различни области на познанието. Използва се фактът, че след първоначалното описание на обекта чрез косвени диагностични признаци, се търси най – добрата класификация или клъстеризация на състоянията му чрез формални математически процедури за оценка на близостта или подобие то между тях. Формалната задача на класификацията се свежда до групиране на множеството от точки в пространството на признаците в подмножества (класове, образи, клъстери), а самото разпознаване се състои в причисляване на текущото състояние към най – близко разположения клас.

Ключови думи: косвени признаци, клъстери, разпознаване

The work explores the possibilities of establishing a general algorithmic basis for assessing the status of a wide range of sites from different areas of knowledge. Presumed is the fact that after the initial description of the site through indirect diagnostic signs a better classification or clustering of states through its formal mathematical procedures has been looked for in order to assess the proximity or similarity between them. The formal task of classification is restricted to grouping a set of points in the space of signs in subsets (classes, images, clusters) and the very recognition consists in the assignment of the current state to the proximal end.

Keywords: indirect signs clusters recognition

Увод. Оценката на състоянието на техническите, биологичните, екологичните и обществените системи може да бъде надеждно решена чрез анализ на големи обеми от данни и приемане на обосновани класифициращи и управляващи решения. В един по – тесен аспект съществува мнението, че тези задачи следва да се решават от технолозите и тесните специалисти в конкретните области. Създава се впечатление, че принципите за оценка на състоянието даже и в една и съща област се отличават по между си и не съществува общ формален метод за класификация не зависещ

от конкретните области на приложение. В действителност това не е така, такива общи методи съществуват и те могат да бъдат получени на базата на теорията за разпознаване на образи.

В един по-тесен смисъл целта на настоящата разработка е да бъде направена оценка на влиянието на интензивността на източника на техногенно замърсяване върху състоянието на почвата и растителността.

Модел за статистическо разпознаване на образи. Основните парадигми в статистическото разпознаване на образи са много близки до реалната физическа

същност на процесите, протичащи в биологичните, обществени, технически, екологични и други системи.

1. Решението за всяко конкретно действие се взема след разпознаване на състоянието, оценка на риска и прогнозиране на последиците от съответното действие.

2. Основната задача на статистическото разпознаване е причисляването на конкретния обект (ситуация, образ, сигнал, измерване) към един от класовете на предварително обособена група от състояния. В този смисъл това е задача за класификация т.е. за избор на най – подходящата оценка на т.н. класификатор. Класовете на състоянието при наличие на две алтернативи могат да бъдат ”добро състояние – лошо състояние”. При три класа състоянията могат да отразяват последователно влошаващи се алтернативи и т.н. (x_1, x_2, \dots, x_n).

3. Информацията за принадлежността на конкретен обект (състояние) към най-близкия до него клас от предварително въведената група от образи се съдържа в определена съвкупност от числово кодирани признаци, организирани в m - мерен вектор на наблюдението.

4. Приемаме, че изменения в структурата и стойностите на вектора на наблюдение са възможни и могат да доведат до грешки в кода. В този смисъл следва да очакваме, че границите между класовете на състояние в пространството на признаците не са ясно очертани, което означава, че в това пространство образите са размити и се пресичат.

5. Методите за разпознаване на образи и класификация се основават на приемане на решения за отнасяне на разпознавания обект към най – близко разположения до него клас. Като мярка за близост може да се използва разстоянието в евклидов или друг геометричен смисъл (степен на подобие между образите, вероятност за принадлежност на образа към съответния клас, стойността на риска при приетото класифициращо решение и др). Като се придържаме към статистическите методи за разпознаване и класификация, ние се ориентираме към последните две мерки за близост.

6. От основната парадигма на разпознаването следва, че за да може да се класифицират състоянията, разпознаващият субект (човек, компютър, правило, алгоритъм) трябва да бъде обучен за това. Това обучение се осъществява най – често по процедурата известна като „ обучение с учител”, при която на обучаемия се представят образи или съвкупности от признаци, по които той осъществява съответното разпознаване. В този смисъл можем да говорим за един общ адаптивен подход, състоящ се от две части: обучение и разпознаване.

7. Статистическото разпознаване на образи дава възможност в процеса на адаптация да се използват различни видове и източници на информация – експертна, литературна, експериментална, получена от предходни изследвания и др.

При тези предпоставки, които са достатъчно общи и не налагат никакви ограничения върху която и да е конкретна задача, класификацията може да бъде решена за два случая:


Класифициращото решение се взема в резултат на измерване и анализ на един вторичен признак (едномерен вектор на наблюдение).

Най – доброто класифициращо решение се търси в резултат на анализ на измененията на съвкупност от признаци (многомерен вектор на наблюдение).

И в двата случая може да бъдат получени процедури за класификация при два, три или повече класове на състоянието.

А. Приемане на оптимални класифициращи решения при едномерни вектори на наблюдение

Приемаме априори, че състоянието , представляващо пълна група от несъвместими събития (например добро x_1 и недобро x_2) се описва с помощта на един контролируем признак (например съдържанието на тежък метал в някоя от растителните фракции или външни промени в структурата на растението). При това законите на разпределение на вторичния признак u , получени в резултат на предварителни експерименти съществено се пресичат (фиг.1)



Фиг.1 Пресичане на едномерни области и граници между тях

Предполагаме, че в резултат на предварителни изследвания или по други съображения са получени оценките на априорните вероятности за поява на всеки от класовете на състоянието P_I и P_{II} . Наблюденията, проведени в рамките на

всеки от двата класа на състояние са ни позволили да определим оценките на плътностите на разпределение на наблюдавания признак във всеки от класовете x_1 и x_2 . т.е

$$f_1(y) = f(y/x_1); \quad f_2(y) = f(y/x_2)$$

Задачата, която си поставяме е да намерим най – добрата в предварително избран смисъл оценка на разделящата граница между двата класа, която в случая ще бъде търсената стойност y_0 . Отчитайки възможността за достатъчно широк кръг от

алгоритми ще приемем използваното в [1] понятие „оптималност” в Баесов смисъл. В този случай класифициращото решение се свежда до приемането на онази алтернатива (клас на състояние), чиято апостериорна вероятност е по – голяма т.е.:

$$y \in x_1, \text{ ако } P_1 \cdot f_1(y) > P_2 \cdot f_2(y); \quad (i, j = 1, 2, i \neq j) \quad (1)$$

Или приведено към всяка една от двете алтернативи:

$$\left. \begin{aligned} y \in x_1, \text{ ако } P_1 \cdot f_1(y) > P_2 \cdot f_2(y) \\ y \in x_2, \text{ ако } P_1 \cdot f_1(y) < P_2 \cdot f_2(y) \end{aligned} \right\} \quad (2)$$

При едномодални разпределения може да бъде определена граничната стойност y_0

между двата класа. Тази граница е решение на уравнението

$$y = y_0, \text{ ако } P_1 \cdot f_1(y) = P_2 \cdot f_2(y) \quad (3)$$

намиращо се между най – вероятните стойности на разпределенията μ_1 и μ_2 , които представляват и съответните математически очаквания.

Стойността на разделящата граница между класовете може да бъде определена например ако са потвърдени хипотезите за нормалност на разпределенията

$$f(y/x_1) = \frac{1}{\sigma_1 \sqrt{2\pi}} \cdot \exp\left[-\frac{(y - \mu_1)^2}{2 \cdot \sigma_1^2}\right]; \quad f(y/x_2) = \frac{1}{\sigma_2 \cdot \sqrt{2\pi}} \cdot \exp\left[-\frac{(y - \mu_2)^2}{2 \cdot \sigma_2^2}\right] \quad (4)$$

където:

μ_1, μ_2 - математически очаквания на признака y в класовете x_1 и x_2 съответно;

σ_1^2, σ_2^2 - дисперсии на разпределенията $f_1(y)$ и $f_2(y)$.

След заместване на (4) в (3) получаваме:

$$\frac{P_1}{\sigma_1} \cdot \exp\left[-\frac{(y-\mu_1)^2}{2 \cdot \sigma_1^2}\right] = \frac{P_2}{\sigma_2} \cdot \exp\left[-\frac{(y-\mu_2)^2}{2 \cdot \sigma_2^2}\right] \quad (5)$$

След логаритмуване на (5) получаваме квадратното уравнение:

$$\frac{(y-\mu_2)^2}{2 \cdot \sigma_2^2} - \frac{(y-\mu_1)^2}{2 \cdot \sigma_1^2} = \ln \frac{P_2 \cdot \sigma_1}{P_1 \cdot \sigma_2} \quad (6)$$

Окончателният вид на уравнението е:

$$\frac{y^2}{2} \cdot \left(\frac{1}{\sigma_2^2} - \frac{1}{\sigma_1^2}\right) + y \left(\frac{\mu_1}{\sigma_1^2} - \frac{\mu_2}{\sigma_2^2}\right) + \left(\frac{\mu_2^2}{2 \cdot \sigma_2^2} - \frac{\mu_1^2}{2 \cdot \sigma_1^2}\right) = \ln \frac{P_2 \cdot \sigma_1}{P_1 \cdot \sigma_2} \quad (7)$$

Търсената стойност $y = y_0$ е този корен на квадратното уравнение (7), който е разположен между центровете на двете разпределения μ_1 и μ_2 .

В случай, че априорните вероятности на класовете на състоянието са равни ($P_1 = P_2$) или не представляват интерес за задачата, уравнението е:

$$\frac{y^2}{2} \cdot \left(\frac{1}{\sigma_2^2} - \frac{1}{\sigma_1^2}\right) + y \left(\frac{\mu_1}{\sigma_1^2} - \frac{\mu_2}{\sigma_2^2}\right) + \left(\frac{\mu_2^2}{2 \cdot \sigma_2^2} - \frac{\mu_1^2}{2 \cdot \sigma_1^2}\right) = \ln \frac{\sigma_1}{\sigma_2} \quad (8)$$

Ако априорните вероятности не са равни ($P_1 \neq P_2$), но дисперсиите на признака в двата класа на състояние са равни

($\sigma_1 = \sigma_2 = \sigma$), уравнението става линейно, а решението е:

получаваме класическото решение отговарящо на т.н. минимаксна стратегия:

$$y_0 = \frac{\mu_1 + \mu_2}{2} \quad (10)$$

След определянето на y_0 по една от стратегиите 7, 8, 9 или 10 достигаме до съвсем прост алгоритъм за разпознаване:

Наблюдението y_i представено за разпознаване се отнася към класа x_1 , ако $y_i < y_0$; в противен случай, то се отнася към x_2 .


При повече от два класа първо се определят границите между всяка двойка от състояния, след което разпознаванията се извършват по същата процедура.

$$y_0 = \frac{\sigma^2}{\mu_2 - \mu_1} \cdot \ln \frac{P_1}{P_2} + \frac{\mu_1 + \mu_2}{2} \quad (9)$$

Стеснявайки още повече условията на задачата до случая $P_1 = P_2$ и $\sigma_1 = \sigma_2$

Б. Приемане на оптимални класифициращи решения при многомерни вектори на наблюдение

Тази задача е едно разширение на предходната по отношение на размерността на вектора на наблюдение (фиг.2). В кръга на решаваните от нас задачи тя може да се използва при косвена оценка на състоянието на една оценявана екосистема по резултатите от наблюдение на косвени вторични признаци (например оценка на количеството на тежките метали в почвата по резултатите от наблюдение на външните белези на растенията и техните фракции).



Фиг. 2 Многомерен случай. Пресичане на класове и граници между тях

По принцип в този случай, правилото за приемане на класифициращи решения може да бъде получено от условието за максимизация на апостериорната вероятност.. Ние ще приложим обаче една по – широка формулировка на задачата [2,3] свеждаща търсенето на такова приложение на разделящата граница, при което се осигурява минимална стойност на риска, т.е. на средните загуби за всички случаи, представени за разпознаване. От факта, че многомерните разпределения на вектора на вторичните косвени признаци за класовете на състояние (два, три или повече) се пресичат (фиг.2) следва, че за всеки представен за разпознаване вектор на наблюдение (например при задача с две състояния – добро или недобро) са възможни четири случая.:

наблюдението, представено с вектора \bar{y}_i е от класа на добрите състояния (условно наречен първи) и то е било правилно класифицирано към него (област Γ_1). Стойността на разходите за приемане на това решение е C_{11} ;

наблюдението \bar{y}_i е от класа на добрите състояния, но е било погрешно класифицирано към недобрите (област Γ_2). Този случай е известен в изследването на операциите като грешка от първи род или „лъжлива тревога” . Стойността на загубите при допускане на тази грешка е C_{12} ;

наблюдението \bar{y}_i е от класа на недобрите състояния и то е било правилно класифицирано към него (област Γ_2). Стойността на разходите е C_{22} ;

наблюдението \bar{y}_i е от класа на недобрите състояния, но е било неправилно класифицирано като добро (област Γ_1). Този случай е известен като грешка от втори род или „пропуск на полезния сигнал”. Стойността на загубите при допускане на такава грешка е равна на C_{21} .

Естествено е да се приеме, че в нормална ситуация загубите при приемане на неправилните решения, са по – големи от разходите за приемане на правилни решения т.е. $C_{11} < C_{12}$ и $C_{22} < C_{21}$. Приемаме, че познаваме условните многомерни плътности на разпределение на вероятностите на вектора \bar{y} във всеки от класовете на състояние $f(y/x_1), f(y/x_2)$ и те се пресичат в пространството на косвените признаци (фиг.2). Познаваме и априорните вероятности на всеки от класовете на състояние $P(x_1)$ и $P(x_2)$.

На базата на тази априорна информация можем да пресметнем средните стойности (загуби) на всяко решение при многократно разпознаване.

$$P_1 = \int_{\Gamma_1} \dots \int C_{11} \cdot P(x_1) \cdot f(\bar{y}/x_1) \cdot d\bar{y}$$

средна стойност, която трябва да се заплати при

многократно разпознаване и приемане на правилни класифициращи решения $\bar{y}_i \in x_1$;

$$\varepsilon_1 = \int_{\Gamma_2} \dots \int C_{12} \cdot P(x_1) \cdot f(\bar{y}/x_1) \cdot d\bar{y}$$

средна стойност на грешките от първи род при

многократно разпознаване с невярно заключение $\bar{y}_i \in x_2$;

$$P_2 = \int_{\Gamma_2} \dots \int C_{22} \cdot P(x_2) \cdot f(\bar{y}/x_2) \cdot d\bar{y}$$

средна стойност на правилните класифициращи

решения $\bar{y}_i \in x_2$ при многократни разпознавания;

$$\varepsilon_2 = \int_{\Gamma_1} \dots \int C_{21} \cdot P(x_2) \cdot f(\bar{y}/x_2) \cdot d\bar{y}$$

средна стойност, която трябва да се заплати при вземане на погрешни разпознаващи

решения $\bar{y}_i \in x_1$.

След сумиране на горните изрази многократно разпознаване на неизвестни получаваме израз за средната стойност, вектори на наблюдение, т.е. функцията на която трябва да бъде заплатена при средния риск:

$$R = P_1 + \varepsilon_1 + P_2 + \varepsilon_2 = \int_{\Gamma_1} \dots \int C_{11} \cdot P(x_1) \cdot f(\bar{y}/x_1) \cdot d\bar{y} + \int_{\Gamma_2} \dots \int C_{12} \cdot P(x_1) \cdot f(\bar{y}/x_1) \cdot d\bar{y} +$$

$$+ \int_{\Gamma_2} \dots \int C_{22} \cdot P(x_2) \cdot f(\bar{y}/x_2) \cdot d\bar{y} + \int_{\Gamma_1} \dots \int C_{21} \cdot P(x_2) \cdot f(\bar{y}/x_2) \cdot d\bar{y} = \min \quad (11)$$

Като се има предвид, че в пространството на състоянията при вече фиксирана разделяща функция двата класа на състояния

(Γ_1 и Γ_2) не се пресичат (те са пълна група от несъвместими събития) т.е.:

$$\int_{\Gamma_2} \dots \int f(\bar{y}/x_j) \cdot d\bar{y} = 1 - \int_{\Gamma_1} \dots \int f(\bar{y}/x_j) \cdot d\bar{y}, \quad (j=1,2) \quad (12)$$

можем да запишем математическото очакване на функцията на средния риск във вида:

$$R = C_{11} P(x_1) + C_{22} P(x_2) +$$

$$+ \int_{\Gamma_1} \dots \int \left[-(C_{12} - C_{11}) \cdot P(x_1) \cdot f(\bar{y}/x_1) + (C_{21} - C_{22}) \cdot P(x_2) \cdot f(\bar{y}/x_2) \right] \cdot d\bar{y} = \min \quad (13)$$

За да определим границата y_0 между двата класа на състояние x_1 и x_2 изхождаме от класическото необходимо условие за наличие на екстремум.

$$\frac{dR}{d\bar{y}} = 0 \quad \text{при } \bar{y} = y_0 \quad (14)$$

При това се има предвид, че в многомерния случай границата между класовете на състоянието е съвкупност от (n-1) на брой хиперплоскости и като такава не може да бъде аналитично записано. Може обаче да бъде определена обаче критичната (оптимална) стойност на отношението на правдоподобие:

$$\lambda = f(\bar{y}/x_1) / f(\bar{y}/x_2) \quad (15)$$

по значенията на която се приема класифициращото решение, минимизиращо средния риск.

В [1] е установено, че след прилагане на процедурата (14) към функцията на риска (13) се получава следното правило за приемане на решения:

$$\left. \begin{aligned} \bar{y}_i \in x_1, \text{ ако } \ln \lambda > \ln \lambda_0 \\ \bar{y}_i \in x_2, \text{ ако } \ln \lambda < \ln \lambda_0 \end{aligned} \right\} \quad (15)$$

където:

$$\ln \lambda = \ln \frac{f(\bar{y}/x_1)}{f(\bar{y}/x_2)}; \text{ а } \ln \lambda_0 = \ln \frac{P(x_2) \cdot (C_{21} - C_{22})}{P(x_1) \cdot (C_{12} - C_{11})} \quad (16)$$

Правилото за приемане на решение съгласно процедурата (15), (16) може да бъде приложено ако са известни многомерните плътности на разпределение на вектора на наблюдение във всеки от класовете. В [1] е получено практически приложимо правило

за приемане на класифициращо решение при известни условни многомерни нормални разпределения на признаците по класовете x_1 и x_2 .

$$\left. \begin{aligned} f(\bar{y}/x_1) = f_1(\bar{y}) = (2\pi)^{-\frac{m}{2}} |V_1|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\bar{y} - \bar{\mu}_1)^T \cdot V_1^{-1} (\bar{y} - \bar{\mu}_1) \right] \\ f(\bar{y}/x_2) = f_2(\bar{y}) = (2\pi)^{-\frac{m}{2}} |V_2|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\bar{y} - \bar{\mu}_2)^T \cdot V_2^{-1} (\bar{y} - \bar{\mu}_2) \right] \end{aligned} \right\} \quad (17)$$

Тук с μ_j и V_j ; ($j=1,2$) са означени съответно векторите на математическото очакване (с размерност “ m ”) и ковариационните матрици (с размерност $m \times m$)

m) за всеки от класовете, а “ T ” е знак за транспониране.

След заместване на условните плътности на разпределение (17) в процедурата (15), (16) получаваме правилото за приемане на решение, минимизиращо средния риск:

$$\left. \begin{aligned} \bar{y}_i \in x_1, \text{ ако } -\frac{1}{2} (\bar{y}_i - \bar{\mu}_1)^T \cdot V_1^{-1} (\bar{y}_i - \bar{\mu}_1) + \frac{1}{2} (\bar{y}_i - \bar{\mu}_2)^T \cdot V_2^{-1} (\bar{y}_i - \bar{\mu}_2) > \\ \frac{1}{2} \ln \frac{|V_1|}{|V_2|} + \ln \frac{P_2(C_{21} - C_{22})}{P_1(C_{12} - C_{11})} \end{aligned} \right\} \quad (18)$$

$\bar{y}_i \in x_2$ ако неравенството е с обратен знак.

Ако $P_1 = P_2$ и $(C_{21} - C_{22}) = (C_{12} - C_{11})$ правилото за приемане на решение е:

$$\left. \begin{aligned} \bar{y}_i \in x_1, \text{ ако } -\frac{1}{2} (\bar{y}_i - \bar{\mu}_1)^T \cdot V_1^{-1} (\bar{y}_i - \bar{\mu}_1) + \frac{1}{2} (\bar{y}_i - \bar{\mu}_2)^T \cdot V_2^{-1} (\bar{y}_i - \bar{\mu}_2) > \\ \frac{1}{2} \ln \frac{|V_1|}{|V_2|} \end{aligned} \right\} \quad (19)$$

$\bar{y}_i \in x_2$ ако неравенството е с обратен знак.

Ако ковариационните матрици са равни $V_1 = V_2 = V$ получаваме линейния алгоритъм за разпознаване, известен още като

дискриминантно правило, минимизиращо средния риск:

$$\left. \begin{aligned} \bar{y}_i \in x_1, \text{ ако } \bar{y}_i^T \cdot V^{-1}(\bar{\mu}_1 - \bar{\mu}_2) - \frac{1}{2}(\bar{\mu}_1 - \bar{\mu}_2)^T \cdot V^{-1}(\bar{\mu}_1 - \bar{\mu}_2) > \\ \ln \frac{P_2(C_{21} - C_{22})}{P_1(C_{12} - C_{11})} \end{aligned} \right\} \quad (20)$$

$y_i \in x_2$, ако неравенството е с обратен знак.

Ако едновременно са изпълнени условията $P_1 = P_2$, $(C_{21} - C_{22}) = (C_{12} - C_{11})$ и $V_1 = V_2 = V$ получаваме линейния дискриминантен алгоритъм, оптимален по принципа на максималното правдоподобие.

$$\left. \begin{aligned} \bar{y}_i \in x_1, \text{ ако } \bar{y}_i^T \cdot V^{-1}(\bar{\mu}_1 - \bar{\mu}_2) - \frac{1}{2}(\bar{\mu}_1 + \bar{\mu}_2)^T \cdot V^{-1}(\bar{\mu}_1 - \bar{\mu}_2) > 0 \end{aligned} \right\} \quad (21)$$

$y_i \in x_2$, ако неравенството е с обратен знак.

3. Разпознаване на представеното наблюдение по вече обучен алгоритъм.

Един по – внимателен поглед показва, че правилата за приемане на решение (18), (19), (20), (21) са многомерни аналози на едномерните правила съответно (7), (8), (9), (10).

Резултати и обсъждане. На базата на така получените теоретични зависимости е предложен един общ алгоритмичен подход със следните характеристики:

Линейните дискриминантни алгоритми (20), (21) са най – широко използвани за многомерна класификация и разпознаване. Те дават добри резултати както при десетични, така и при двоично – кодирани признаци, даже и в случаите когато ковариационните матрици не са еднакви.

- Възможност за разпознаване при голям брой на класовете на състояние.

При необходимост от разпознаване на повече от два класа (многоалтернативна задача) се постъпва по два начина [1,4]:

- Проста и лесна реализация на разпознаващата процедура, която ще се извършва ”на терен” и в реално време.

1. По вече разгледаните двуалтернативни процедури се провежда разпознаване за всички двойки от класовете (n-1).

- Прехвърляне на всички тежки изчислителни процедури върху процеса на обучение, който ще се осъществява предварително в лабораторни условия.

2. Съставят се n- на брой еднокласни функции и наблюдението се причислява към класа с най – голямата стойност, получена за конкретното y_i .

Провеждането на обучението изисква сериозни лабораторни и компютърни ресурси, усилия и математически познания, които се свеждат до определянето от базите данни на векторите на математическите очаквания, на ковариационните матрици и на коефициентите в линейните форми. Алгоритъмът е много прост и може лесно да бъде реализиран на ръка или с елементарен калкулатор. Това е проверено на базата на обучение и разпознаване на големи бази от данни за различни екосистеми.

За прилагането на методите на статистическа класификация се преминава през следните етапи:

1. Определяне на броя на класовете на състояние (предварително обучение).

Results and discussion. Based on the so obtained theoretical dependencies a general algorithmic approach with the following characteristics has been proposed:

2. Избор на разпознаващия алгоритъм и провеждане на обучение, свеждащо се до определяне на статистическите характеристики по класове (математическо очакване, дисперсии, ковариационни матрици).

- Ability to recognize a large number of classes of state.

- Simple and easy implementation of the recognition procedure will be carried out "on the field" and in real time.

- Transfer of all heavy computational procedures on the learning process, which will be carried out in advance in the laboratory.

Conducting the training requires serious laboratory and computing resources, effort and

mathematical knowledge, limited to the determination of the databases of the vector mathematical expectations, covariance matrices and the coefficients in linear forms. The algorithm is very simple and can easily be carried out by hand or with a simple calculator.

Литература: 1. А.Недев. „Разпознаване на образи и оптимално стохастическо управление“ ИК „Геа-Принт“ Варна, 2012., 345 с. 2. А.Недев, К. Тенкеджиев Техническа диагностика и разпознаване на образи, ТУ – Варна 1997., 480 с. 3. Duda R.O., Hart P.E. „Pattern classification and scene analysis” D.Wiley. New York. 1973г., 510 p. 4. Atanassov A. N., Karastatev D. “late quantitative functional prognosis in rehabilitated patients with acute myocardial infarction”. IX World Congress of Cardiology, Moscow 1982., Vol II.