

ОПТИМИЗАЦИЯ СИНТЕЗА ГИPERПЛОСКОСТНЫХ КЛАСТЕРОВ И НЕЙРОФУНКЦИОНАЛЬНЫХ ПРЕОБРАЗОВАНИЙ В СИСТЕМАХ КЛАССИФИКАЦИИ СИГНАЛОВ

Ключевые слова: кластеризация, синтез систем классификации, распознавание образов, псевдообратные и проекционные матрицы.

ВВЕДЕНИЕ

Статья является логическим продолжением исследований задач кластеризации и классификации сигналов, изложенных в работах [1, 2]. Для исследования этих задач, как и ранее, используются известные [3–5] и ранее полученные авторами свойства псевдообратных и проекционных матриц [6–8]. Цель данной работы состоит в демонстрации эффективности использования этого математического аппарата при решении важных задач цифровой обработки информации. А именно: для задач кластеризации множества точек в пространстве признаков получен оптимизационный алгоритм синтеза гиперплоскостных кластеров, предлагается алгоритм решения задачи линейной отделимости конечного множества точек, определен критерий линейной полосной разделимости точек в пространстве признаков на два класса, определена оптимальная по толщине нелинейная полоса разделимости точек на два класса, разработан алгоритм определения оптимального нелинейного преобразования координаты вектора признаков в заданных классах функций и ее индекса. С точки зрения авторов, предлагаемые математические средства имеют перспективу существенно улучшить решение прикладных задач распознавания речевых сигналов, человеческих лиц, рукописных символов и текстов, ультразвуковой информации, экономических ситуаций, других сигналов и событий.

1. СИНТЕЗ ГИPERПЛОСКОСТНЫХ КЛАСТЕРОВ СРЕДСТВАМИ ОПТИМИЗАЦИИ

1.1. Краткий обзор средств кластеризации. При большом разнообразии различных методов кластеризации (краткий обзор приведен в [9]) остановимся на нескольких приемлемых для использования в нашей задаче методах кластеризации в пространстве признаков.

Довольно часто используется алгоритм кластеризации K -средних (K -means method) [10], в котором формируется некоторая целевая функция $\Phi(\cdot)$, выражающая качество текущего разбиения множества точек $x(j)$, $j = \overline{1, n}$, на K кластеров с центрами в точках c_i , $i = \overline{1, K}$, K — задано. В начальный момент центры кластеров выбираются произвольно, далее для каждой точки множества итеративно определяем его принадлежность к одному из K кластеров и вычисляем новые значения $\Phi(\cdot)$ для центров кластеров, стремясь при этом минимизировать функцию $\Phi(\cdot)$. В литературе можно найти различные его модификации [10].

Одним из классических считается метод сегментации информации, основанный на разбиении и слиянии кластеров (split and merge methods) [11]. В начальный момент единственным регионом является все множество точек $x(j)$, $j = \overline{1, n}$, и на каждой итерации метода производится расщепление каждого региона R_i , для которого не выполняется условие $P(R_i)$ принадлежности точек к i -му региону, на некоторое количество подрегионов. Далее сливаются те смежные регионы R_i и R_k , для объединения которых $P(R_i \cup R_k)$ это условие выполняется. Процесс заканчивается,

если существующие регионы невозможно ни расщепить, ни объединить. В качестве логического предиката $P(\cdot)$ можно использовать, например, критерий K -means метода, либо строить различные меры подобия [10].

Среди множества других публикаций по этой проблеме следует отметить фундаментальную работу [12], в которой дается детальный анализ и обзор различных методов, в том числе класс методов последовательного формирования кластеризующих подпространств (The Subspaces Methods of Classification), которые в определенном смысле идейно близки к предлагаемому ниже авторами методу кластеризации.

1.2. Постановка задачи синтеза гиперплоскостных кластеров средствами оптимизации и алгоритм ее решения. Рассмотрим задачу синтеза гиперплоскостных кластеров, используя ранее полученные результаты по псевдообратным и проекционным матрицам, а также свойства сингулярного разложения матриц [4, 5].

Для множества точек в пространстве признаков $x(j) \in R^m$, $j = \overline{1, n}$, рассмотрим задачу разделения этого множества на два кластера (подмножества) таким образом, чтобы точки первого кластера были расположены ближе к некоторой гиперплоскости, порождающей свой класс, а точки второго кластера, в свою очередь, ближе к иной гиперплоскости и соответственно порождающей этот класс. Особенностью постановки рассматриваемой задачи является то обстоятельство, что заранее ни сами эти подмножества, ни порождающие гиперплоскости неизвестны.

Для формулирования этой задачи в математическом смысле и построения алгоритма ее решения введем в рассмотрение расстояние $\rho(x(j), L(A, b))$ от точки $x(j) \in R^m$ до некоторой гиперплоскости

$$L(A, b) = \{x: x = A^+ b + Z(A)w, \forall w \in R^m\}, \quad (1)$$

определенное как множество решений (псевдорешений) системы алгебраических уравнений

$$Ax = b, A \in R^{s \times m}, b \in R^s, \quad (2)$$

где A и b — соответственно матричный и векторный параметры рассматриваемой гиперплоскости, а $Z(A) = I_m - A^+ A$. Из определения псевдообратной матрицы A^+

$$\forall b \in R^s, A^+ b = \arg \min_{\substack{\text{Arg} \\ x \in R^m}} \|Ax - b\|^2$$

расстояние $\rho(x(j), L(A, b))$ от точки $x(j)$ до гиперплоскости $L(A, b)$ определяется согласно соотношению

$$\rho^2(x(j), L(A, b)) = \|A^+(b - Ax(j))\|^2, \quad (3)$$

где $\|x\|^2 = x^T x$.

Тогда справедливо утверждение следующей леммы.

Лемма 1. Для множества точек $x(j)$, $j = \overline{1, n}$, сумма квадратов их расстояний до гиперплоскости $L(A, b)$

$$\rho^2(\{x: x(j), j = \overline{1, n}\}, L(A, b)) = \sum_{j=1}^n \rho^2(x(j), L(A, b)) \quad (4)$$

принимает значение

$$\begin{aligned} \rho^2(\{x: x(j), j = \overline{1, n}\}, L(A, b)) &= \sum_{j=1}^n (b - Ax(j))^T R(A^T)(b - Ax(j)) = \\ &= \text{tr } R(A^T) \sum_{j=1}^n (b - Ax(j))(b - Ax(j))^T, \end{aligned} \quad (5)$$

где $R(A^T) = (A^+)^T A^+$ — взвешенная проекционная матрица [7].

Используя свойства псевдообратных матриц, несложно осуществить доказательство леммы об оптимальном выборе вектора b .

Лемма 2. При заданных значениях $A, x(j), j=1, n$, имеет место соотношение

$$b_{\text{opt}} = A\hat{x} = \arg \min_{b \in R^s} \rho^2(\{x: x(j), j=\overline{1, n}\}, L(A, b)), \quad \hat{x} = \frac{1}{n} \sum_{j=1}^n x(j). \quad (6)$$

Доказательство. На основании соотношения (5) и в силу необходимого условия оптимальности

$$\sum_{j=1}^n (A^+)^T A^+ (b - Ax(j)) = 0 \quad (7)$$

для искомого оптимального значения вектора b получаем систему уравнений

$$(A^+)^T A^+ b = (A^+)^T \left(\frac{1}{n} \sum_{j=1}^n x(j) \right), \quad (8)$$

которая является совместной и существование решения которой вытекает из очевидного соотношения

$$\left\| Z((A^+)^T A^+) (A^+)^T \sum_{j=1}^n x(j) \right\|^2 = 0.$$

Поскольку $((A^+)^T A^+)^+ = AA^T$, то

$$b_{\text{opt}}(A) = AA^T (A^+)^T \left(\frac{1}{n} \sum_{j=1}^n x(j) \right) = A \left(\frac{1}{n} \sum_{j=1}^n x(j) \right). \quad (9)$$

Теорема. Расстояние $\rho(\{x: x(j), j=\overline{1, n}\}, L(A, b))$ множества точек $x(j), j=\overline{1, n}$, до гиперплоскости $L(A, b)$ при оптимальном выборе вектора b согласно формуле (6) имеет значение

$$\rho(\{x: x(j), j=\overline{1, n}\}, L(A, b_{\text{opt}}(A))) = (\text{tr } A^+ A \cdot \tilde{X} \tilde{X}^T)^{1/2}, \quad (10)$$

где $\tilde{X} = (\tilde{x}(1) : \dots : \tilde{x}(n))$, $\tilde{x}(j) = x(j) - \hat{x}$, $j=\overline{1, n}$.

Доказательство. Так как имеют место соотношения

$$\begin{aligned} & \rho^2(\{x: x(j), j=\overline{1, n}\}, L(A, b_{\text{opt}})) = \\ & = \sum_{j=1}^n \left(\frac{1}{n} \sum_{i=1}^n Ax(i) - Ax(j) \right)^T (A^+)^T A^+ \left(\frac{1}{n} \sum_{i=1}^n Ax(i) - Ax(j) \right) = \\ & = \sum_{j=1}^n (\hat{x} - x(j))^T A^T (A^+)^T A^+ A (\hat{x} - x(j)) = \sum_{j=1}^n (\hat{x} - x(j))^T A^+ A (\hat{x} - x(j)) = \\ & = \sum_{j=1}^n \tilde{x}^T(j) A^+ A \tilde{x}(j) = \text{tr } A^+ A \cdot \sum_{j=1}^n \tilde{x}(j) \tilde{x}^T(j) = \text{tr } A^+ A \tilde{X} \tilde{X}^T, \end{aligned}$$

то справедливость теоремы не вызывает сомнения.

Средство оптимального выбора матрицы A получим как следствие из утверждения предыдущей теоремы. А именно, используя известное сингулярное разложение для матрицы \tilde{X}

$$\tilde{X} = \sum_{i=1}^r u_i v_i^T \lambda_i, \quad u_i^T u_j = \delta_{ij}, \quad v_i^T v_j = \delta_{ij}, \quad \lambda_1 \geq \dots \geq \lambda_r > 0, \quad r = \text{rank } \tilde{X},$$

для следующего представления расстояния множества точек $x(j), j = \overline{1, n}$, до $L(A, b_{\text{opt}})$

$$\rho(\{x: x(j), j = \overline{1, n}\}, L(A, b_{\text{opt}}(A))) = \left(\text{tr} A^+ A \cdot \sum_{j=1}^r u_j u_j^\top(j) \lambda_j^2 \right)^{1/2},$$

получаем средство оптимального выбора матрицы A .

Следствие. Оптимальный выбор матрицы $A \in R^{s \times m}$ определяется как решение оптимизационной задачи

$$A_{\text{opt}} = \arg \min_{AA^\top = I_s, A \in R^{s \times m}} \rho^2(\{x: x(j), j = \overline{1, n}\}, L(A, b_{\text{opt}}(A))) = \begin{pmatrix} u_{m-s+1}^\top \\ \vdots \\ u_m^\top \end{pmatrix}, \quad (11)$$

при этом $\text{tr} A_{\text{opt}}^+ A_{\text{opt}} \tilde{X} \tilde{X}^\top = \sum_{j=m-s+1}^r \lambda_j^2$, $(u_1, \dots, u_m)^\top (u_1, \dots, u_m) = I_m$.

На основании приведенных выше лемм, теоремы и следствия алгоритм синтеза гиперплоскостных кластеров представляется аналогично алгоритму *K*-средних:

1) создать начальное разбиение исходного множества $\Omega_x = \{x: x(j), j = \overline{1, n}\}$ на два подмножества:

$$\Omega_x = \Omega_x(1) \cup \Omega_x(2), \quad \Omega_x(1) \cap \Omega_x(2) = \emptyset;$$

2) вычислить оптимальные $A_{\text{opt}}(1)$, $b_{\text{opt}}(1)$ для $\Omega_x(1)$ и $A_{\text{opt}}(2)$, $b_{\text{opt}}(2)$ — для $\Omega_x(2)$;

3) обновить $\Omega_x(1)$ и $\Omega_x(2)$ по расстоянию $(b_{\text{opt}} - A_{\text{opt}} x(j))^\top R(A_{\text{opt}}^\top) \times (b_{\text{opt}} - A_{\text{opt}} x(j))$, сформировать новые подмножества $\Omega_x(1)$, $\Omega_x(2)$ из элементов множества Ω_x согласно условиям

$$\begin{aligned} \|A_1^+ (b_1 - A_1 x(j))\|^2 &\leq \|A_2^+ (b_2 - A_2 x(j))\|^2, \\ \|A_2^+ (b_2 - A_2 x(j))\|^2 &< \|A_1^+ (b_1 - A_1 x(j))\|^2; \end{aligned}$$

4) перейти на выполнение операции 2 с новыми подмножествами $\Omega_x(1)$, $\Omega_x(2)$;

5) прекратить выполнение операций при не обновлении в новом цикле значений A_1 , b_1 и A_2 , b_2 .

2. СИНТЕЗ КЛАССИФИКАТОРОВ СРЕДСТВАМИ ЛИНЕЙНЫХ И НЕЛИНЕЙНЫХ ОПТИМАЛЬНЫХ ПРЕОБРАЗОВАНИЙ ПРОСТРАНСТВА ПРИЗНАКОВ

Для рассматриваемых задач распознавания принадлежности исследуемых объектов к тому или иному классу будем предполагать известным, к какому из классов относятся векторы обучающей выборки $x(j)$, $j = \overline{1, n}$, в пространстве признаков. Тогда целесообразно рассмотреть последовательно такие постановки задач:

— определить необходимые и достаточные условия линейной отделимости конечного множества точек в многомерном пространстве;

— определить необходимые и достаточные условия линейной полосной разделимости точек $x(j)$, $j = \overline{1, n}$, на два класса;

— определить оптимальную по толщине нелинейную полосу разделимости точек $x(j)$, $j = \overline{1, n}$, на два класса;

— упорядочить координаты $x_i(j)$, $i = \overline{1, m-1}$, $j = \overline{1, n}$, $x_m(j) \equiv 1$, согласно их влиянию или на размеры (толщину) линейной оптимальной полосы, или на критерий линейной полосной разделимости;

— сформулировать правило замены слабо влияющих (неинформационных) координат вектора признаков на более информативные из множества конкурирующих признаков;

— для выбранных согласно прикладной целесообразности классов нелинейных преобразований предложить средства определения оптимального как самого

нелинейного преобразования из выбранного класса некоторой координаты $x_i(j)$, так и индекса i этой координаты (примеры таких классов приводятся ниже);

— сгенерировать суперпозицию оптимальных преобразований координат вектора признаков для достижения условий оптимальной полосной разделимости точек в новом пространстве признаков.

2.1. Условия и оптимизация полосной разделимости образов в пространстве признаков. Сформулируем сначала условия линейной отдельности точек $x(j)$, $j = \overline{1, n}$, от начала координат в пространстве R^m . Используя операции псевдообращения матриц, эту задачу будем понимать и исследовать в смысле существования решения системы относительно вектора $a \in R^m$

$$x^T(j)a = y_j, \quad y_j \geq \Delta, \quad j = \overline{1, n}, \quad (12)$$

при некоторых $\Delta > 0$ и значениях y_j .

Тогда при фиксированном $\Delta > 0$ необходимое и достаточное условие существования решения этой задачи будет иметь вид

$$\min_{y \in D(\Delta)} y^T Z(X)y = y_*^T(\Delta)Z(X)y_*^T(\Delta) = 0, \quad (13)$$

где

$$X = (x(1) : \dots : x(n)) = \begin{pmatrix} x_{(1)}^T \\ \dots \\ x_{(m)}^T \end{pmatrix}, \quad Z(X) = I_n - X^+ X,$$

$$D(\Delta) = \{y: y = (y_1, \dots, y_n)^T, y_j \geq \Delta, j = \overline{1, n}\}. \quad (14)$$

При этом искомый вектор a принимает значение

$$a(\Delta) = (X^T)^+ y_*^T(\Delta), \quad (15)$$

а толщина полосы δ , отделяющей множества точек $x(j)$, $j = \overline{1, n}$, от начала координат, равна величине

$$y_* = \delta = \frac{\Delta}{(y_*^T(\Delta)R(X)y_*^T(\Delta))^{1/2}}, \quad (16)$$

где $R(X) = X^+ (X^T)^+$.

Поскольку $y_*(k\Delta) = k y_*(\Delta)$, то без ограничения общности можно положить $\Delta = 1$, $y_*(1) = y_*$. Следовательно, максимальная толщина полосы достигается при значениях

$$y_{opt} = \arg \min_{y \in D} y^T R(X)y, \quad a_{opt} = (X^T)^+ y_{opt}, \quad (17)$$

где $D = \{y: y^T Z(X)y = y_*^T Z(X)y_* = 0, e_j^T y \geq 1, j = \overline{1, n}\}$. Используя сингулярное разложение матриц (SVD)

$$X = \sum_{j=1}^r u_j v_j^T \lambda_j, \quad Z(X) = I_n - \sum_{j=1}^r v_j v_j^T,$$

$$u_i^T u_j = \delta_{ij}, \quad v_i^T v_j = \delta_{ij}, \quad X X^T u_j = \lambda_j^2 u_j, \quad X^T X v_j = \lambda_j^2 v_j,$$

$$\lambda_1^2 \geq \dots \geq \lambda_r^2, \quad i, j = \overline{1, n},$$

и учитывая, что $y^T Z(X)y = 0$ для $y \in D$, можно записать следующие соотношения:

$$y = \sum_{i=1}^r \alpha_i v_i, \quad \sum_{i=1}^r \alpha_i e_j^T v_i \geq 1 \quad \forall j = \overline{1, n}, \quad y^T R(X)y = \sum_{j=1}^r \alpha_j^2 \lambda_j^{-2}. \quad (18)$$

Таким образом, задача поиска оптимальной линейной отделимости точек $x(j)$, $j = \overline{1, n}$, от начала координат сводится к решению задачи оптимизации квадратичной функции на выпуклом множестве:

$$\begin{aligned} \alpha_{\text{opt}} &= \arg \min_{\alpha \in \{\alpha : e_j^T (v_1 : \dots : v_r) \alpha \geq 1, j = \overline{1, n}\}} \alpha^T \text{diag}(\lambda_1^{-2}, \dots, \lambda_r^{-2}) \alpha, \\ y_{\text{opt}} &= (v_1 : \dots : v_r) \alpha_{\text{opt}}, \\ a_{\text{opt}} &= \sum_{j=1}^r u_j v_j^T \lambda_j^{-1} \cdot (v_1 : \dots : v_r) \alpha_{\text{opt}} = (\lambda_1^{-1} u_1 : \dots : \lambda_r^{-1} u_r) \alpha_{\text{opt}}, \\ \delta_{\text{opt}} &= (\alpha_{\text{opt}}^T \text{diag}(\lambda_1^{-2}, \dots, \lambda_r^{-2}) \alpha_{\text{opt}})^{-1/2}. \end{aligned} \quad (19)$$

Используя приведенные выше условия линейной отделимости точек в R^m для задачи линейной полосной разделимости двух классов точек в пространстве признаков, получим как условия существования решения такой задачи, так и средство получения самого решения. Пусть известно, что для последовательности точек $x(j)$ в пространстве признаков R^m

$$x(j) \in R^m, \quad x(j) = \begin{pmatrix} x_1(j) \\ \vdots \\ x_m(j) \end{pmatrix}, \quad x_m(j) = 1, \quad j = \overline{1, n},$$

точки $x(i_k)$, $k = \overline{1, n_1}$, принадлежат первому классу, а $x(j_s)$, $s = \overline{1, n_2}$ — второму. Тогда линейную полосную разделимость этих классов будем понимать в смысле существования такого вектора $a \in R^m$, для которого

$$\begin{aligned} a^T x(i_k) &\geq 1, \quad k = \overline{1, n_1}, \\ a^T x(j_s) &\leq -1, \quad s = \overline{1, n_2}. \end{aligned} \quad (20)$$

Тогда условие линейной полосной разделимости приобретает вид

$$\min_{y \in D} y^T Z(X) y = 0, \quad D = \{y : e_{i_k}^T y \geq 1, e_{j_s}^T y \leq -1, k = \overline{1, n_1}, s = \overline{1, n_2}\}, \quad (21)$$

а значение вектора a определяется оптимально в смысле максимизации толщины разделяющей полосы

$$y_{\text{opt}} = \arg \min_{y \in D_1} y^T R(X) y, \quad (22)$$

где $D_1 = \{y : y^T Z(X) y = 0\} \cap D$,

$$a_{\text{opt}} = (X^T)^+ y_{\text{opt}}. \quad (23)$$

Применяя представление SVD для матрицы X , эти операции можно интерпретировать в более удобной для использования форме:

$$\begin{aligned} \alpha_{\text{opt}} &= \\ &= \arg \min_{\alpha \in \{\alpha : e_{i_k}^T (v_1 : \dots : v_r) \alpha \geq 1, e_{j_s}^T (v_1 : \dots : v_r) \alpha \leq -1, k = \overline{1, n_1}, s = \overline{1, n_2}\}} \alpha^T \text{diag}(\lambda_1^{-2}, \dots, \lambda_r^{-2}) \alpha, \end{aligned} \quad (24)$$

$$y_{\text{opt}} = (v_1 : \dots : v_r) \alpha_{\text{opt}}, \quad (25)$$

$$a_{\text{opt}} = (u_1 : \dots : u_r) \text{diag}(\lambda_1^{-1}, \dots, \lambda_r^{-1}) \alpha_{\text{opt}}. \quad (26)$$

2.2. Оптимальное нелинейное преобразование компонент вектора признаков. Весьма часто условие линейной полосной разделимости (21) в выбранном пространстве признаков не выполняется, т.е.

$$\min_{y \in D} y^T Z(X) y > 0. \quad (27)$$

В этом случае можно использовать следующие средства возможного выхода из создавшегося положения. Прежде всего попытаться улучшить выбор информативных признаков. Второе средство состоит в использовании каскадного полосного линейного разделения двух классов [1] и, как нам представляется, весьма перспективно синтезировать оптимально суперпозицию нелинейных преобразований в пространстве признаков. Этот синтез предлагается осуществлять поэтапно следующим образом.

Рассмотрим сначала задачу синтеза нелинейного преобразователя при известных входных и выходных данных соответственно: $X = (x(1) : \dots : x(n))$ и $y = (y_1, \dots, y_n)$. Попытаемся путем поиска нелинейного преобразования некоторых компонент вектора $x_{(i)}$, $i = 1, m-1$, изменить их таким образом, чтобы уменьшить невязку $y^T Z(X)y$, и определим среди них оптимальную компоненту с индексом i_0 и соответствующее ей оптимальное преобразование. Для этого выполним указанную последовательность действий:

1) найти $a = (X^T)^+ y$;

2) вычислить

$$a(i) = (X_{(i)}^T)^+ y, \quad X_{(i)} = \begin{pmatrix} x_{(1)}^T \\ \vdots \\ x_{(i-1)}^T \\ x_{(i+1)}^T \\ \vdots \\ x_{(m)}^T \end{pmatrix}, \quad \text{где } i = \overline{1, m-1}; \quad (28)$$

3) образовать вектор отклонений

$$\Delta y_i = (\Delta y_i(1), \dots, \Delta y_i(n))^T, \quad \Delta y_i(j) = y(j) - \hat{y}_i(j), \quad j = \overline{1, n}, \quad (29)$$

где $\hat{y}_i = (\hat{y}_i(1), \dots, \hat{y}_i(n))^T = Z(X_{(i)})y = (I_n - X_{(i)}^+ X_{(i)})y = y - X_{(i)}^T a(i)$;

4) заменить удаленную компоненту $x_i(j)$ нелинейной функцией вида $\varphi(a^T x(j), \alpha(i))$, неизвестные параметры $\alpha(i)$ определяются из условия минимума отклонения

$$\sum_{j=1}^n \|\varphi(a^T x(j), \alpha(i)) - \Delta y_i(j)\|^2. \quad (30)$$

В качестве примера нелинейного преобразования можно рассмотреть сплайны третьего порядка

$$\varphi(a^T x(j), \alpha(i)) = (1 \ z(j) \ z^2(j) \ z^3(j))\alpha(i), \quad z(j) = a^T x(j), \quad j = \overline{1, n},$$

$$\alpha(i) = \left(\sum_{j=1}^n \begin{pmatrix} 1 \\ z(j) \\ z^2(j) \\ z^3(j) \end{pmatrix} (1 \ z(j) \ z^2(j) \ z^3(j)) \right)^+ \sum_{j=1}^n \begin{pmatrix} 1 \\ z(j) \\ z^2(j) \\ z^3(j) \end{pmatrix} \cdot \Delta y_i(j); \quad (31)$$

5) найти компоненту с индексом $i_0 \in \{i: 1, m-1\}$, при которой достигается минимум величины $y^T Z(X_{\varphi, i})y$, где

$$X_{\varphi, i} = (x_{(1)} \dots x_{(i-1)} \varphi_i x_{(i+1)} \dots x_{(m)}), \quad \varphi_i(\varphi(a^T x(1), \alpha(i)) \dots \varphi(a^T x(n), \alpha(i)))^T.$$

Таким образом, на первом этапе получили наилучшее преобразование оптимально выбранной компоненты $x_{(i_0)}$.

Затем для новых входных данных повторяем описанный выше процесс нелинейного преобразования, реализуя, таким образом, суперпозицию нелинейных функциональных преобразований в целях минимизации невязки.

В задаче синтеза нелинейной системы распознавания образов задача усложняется в связи с тем, что выходные данные (вектор y) наперед неизвестны, т.е. если $\min_{y \in D} y^T Z(X) y > 0$, то в этом случае, как правило, такой линейной разделяющей полосы не существует. Возникает вопрос, какие компоненты $x_{(i_0)}$ требуется последовательно нелинейно преобразовать, чтобы разделяющая полоса в новом полученном пространстве входных данных существовала?

Для этого воспользуемся приведенным выше алгоритмом, в котором выходные данные составляют вектор y_* . Этот вектор находим, решая задачу оптимизации квадратичной функции при линейных ограничениях

$$y_* = \operatorname{Arg} \min_{y \in D} y^T Z(X) y, \quad (32)$$

используя одну из модификаций градиентного метода, например описанную в [1].

Далее выполняем все приведенные выше операции пп.1–5, полагая $y = y_*$. Для новых векторов признаков

$$\begin{pmatrix} x_1(j) \\ \vdots \\ x_{i_0-1}(j) \\ \varphi(a^T x(j), \alpha(i_0)) \\ x_{i_0+1}(j) \\ \vdots \\ x_m(j) \end{pmatrix}, \quad j = \overline{1, n}, \quad (33)$$

определяем новое значение $y \in D$, при котором достигается минимум выражения $y^T Z(X_{\varphi, i_0}) y$ и соответствующее новое значение

$$a = (X_{\varphi, i_0}^T)^T y. \quad (34)$$

Если это минимальное значение $y^T Z(X_{\varphi, i_0}) y$ равняется нулю, т.е. выполняется условие линейной полосной разделимости в новом пространстве признаков, то необходимо найти

$$a_{\text{opt}} = (X_{\varphi, i_0}^T)^+ y_{\text{opt}}, \quad y = \arg \min_{y \in D_1} y^T R((X_{\varphi, i_0}^T)^+) y, \quad (35)$$

где $D_1 = \{y: y^T Z(X_{\varphi, i_0}) y = 0\} \cap D$. И, таким образом, построить оптимальную линейную разделяющую операцию $a_{\text{opt}}^T x(i_k) \geq 1, a_{\text{opt}}^T x(j_s) \leq -1, k = \overline{1, n_1}, s = \overline{1, n_2}$, для новых векторов признаков, которые получаются после нелинейного преобразования компонент.

3. ОРГАНИЗАЦИЯ СИСТЕМЫ РАСПОЗНАВАНИЯ ОБРАЗОВ

Рассмотрим структурно организацию системы распознавания образов. Более детальные исследования по задаче организации системы и ее реализации планируется развить в последующей работе авторов.

1. На основе идеальных представителей классов конкретной рассматриваемой предметной области создаем базу данных и средствами синтеза кластеров строим дихотомное дерево классификации образов. На этом этапе решаем задачу выбора характерных признаков классификации и их количество (размерность пространства признаков).

2. На основе уже не идеальных, а реальных представителей классов обучающей выборки для каждой вершины дерева синтезировать оптимальный полосно-разделяющий классификатор согласно информации об объектах, содержащейся в обучающей последовательности.

3. В итоге настроенная таким образом система распознавания может уточняться путем оптимизации всех параметров в ранее организованной структуре, т.е. при этом осуществляется реализация обучения синтезированной системы распознавания образов.

ЗАКЛЮЧЕНИЕ

В настоящей статье осуществляется развитие средств псевдообращения матриц применительно к исследованию задач кластеризации информации и распознаванию образов. Приведенные методы нелинейного преобразования компонент вектора признаков позволяют расширить сферу использования аппарата псевдообращения матриц на нелинейные задачи распознавания образов. В статье предлагаются детальные схемы построения таких алгоритмов, работоспособность которых проверена авторами на решении ряда конкретных задач, связанных с распознаванием ультразвуковых сигналов, рукописных символов. В настоящее время ведется работа по их применению для распознавания содержащейся информации в речевых сигналах.

СПИСОК ЛИТЕРАТУРЫ

1. Кириченко Н.Ф., Кривонос Ю.Г., Лепеха Н.П. Синтез систем нейрофункциональных преобразователей в решении задач классификации // Кибернетика и системный анализ. — 2007. — № 3. — С. 47–57.
2. Кириченко Н.Ф., Донченко В.С., Сербаев Д.П. Нелинейные рекурсивные регрессионные преобразователи: динамические системы и оптимизация // Там же. — 2005. — № 3. — С. 58–68
3. Альберт А. Регрессия, псевдоинверсия, рекуррентное оценивание / Пер. с англ. — М.: Наука, 1977. — 305 с.
4. Форсайт Дж., Малькольм М., Модлер К. Машинные методы математических вычислений / Пер. с англ. — М.: Мир, 1980. — 279 с.
5. Беклемишев Д.В. Дополнительные главы линейной алгебры. — М.: Наука, 1983. — 336 с.
6. Кириченко Н.Ф. Аналитическое представление возмущений псевдообратных матриц // Кибернетика и системный анализ. — 1997. — № 2. — С. 98–107.
7. Кириченко Н.Ф., Лепеха Н.П. Применение псевдообратных и проекционных матриц к исследованию задач управления, наблюдения и идентификации // Там же. — 2002. — № 4. — С. 107–124.
8. Кириченко Н.Ф., Крак Ю.В., Полищук А.А. Псевдообратные и проекционные матрицы в задачах синтеза функциональных преобразователей // Там же. — 2004. — № 3. — С. 116–129.
9. Верченко А.П., Кириченко Н.Ф., Лепеха Н.П. Рекуррентные средства кластеризации в применении к задачам сегментации изображений // Проблемы управления и информатики. — 2005. — № 2. — С. 62–71
10. Форсайт Дж., Понс М. Компьютерное зрение. Современный подход / Пер. с англ. — М.: Вильямс, 2004. — 928 с.
11. Lucchese L., Mitra S. Color image segmentation: A state-of-the-art survey // Proc. of the Indian National Sci. Academ. (INSA-A). — 2001. — 67, N 2. — P. 207–221.
12. Kohonen T. Self-organizing maps. — Berlin: Springer, 2001. — 501 p.

Поступила 03.04.2008