

ИНФОРМАЦИОННО-ЭКСТРЕМАЛЬНЫЙ АЛГОРИТМ ОБУЧЕНИЯ СИСТЕМЫ ДИАГНОСТИРОВАНИЯ ИНФЕКЦИОННЫХ ПАТОЛОГИЙ

А.С. Довбыш, А.А. Стадник, М.С. Руденко

Сумской государственной университет

Рассмотрен метод определения схемы лечения острой кишечной инфекции в рамках информационно-экстремальной интеллектуальной технологии, основанной на максимизации информационной способности компьютеризированной системы диагностирования в процессе ее обучения с оптимизацией уровней селекции координат двоичных эталонных векторов-реализаций образов.

Розглянуто метод визначення схеми лікування гострої кишкової інфекції в рамках інформаційно-екстремальної інтелектуальної технології, заснованої на максимізації інформаційної спроможності комп'ютеризованої системи діагностування в процесі її навчання з оптимізацією рівнів селекції координат двійкових еталонних векторів-реалізацій образів.

Введение

Анализ существующих компьютеризированных систем диагностирования (КСД) и лечения инфекционных патологий свидетельствует об их недостаточной функциональной эффективности [1–2], поскольку принятие диагностических решений по-прежнему остается функцией врача. Поэтому актуальной задачей является наделение системы поддержки принятия решений (СППР) как основной составляющей КСД свойством адаптивности путем машинного обучения и распознавания образов. Известные методы распознавания образов [3–5] в основном носят модельный характер, что позволяет объяснить механизм принятия решений, но они не пригодны к использованию в практических задачах диагностики и лечения, поскольку не учитывают произвольные начальные условия и пересечение классов распознавания, характеризующих функциональное состояние наблюдаемого патологического процесса.

Одним из перспективных направлений повышения функциональной эффективности КСД является использование идей и методов информационно-экстремальной интеллектуальной технологии (ИЭИ-технологии), которая основывается на максимизации информационной способности СППР в процессе ее машинного обучения [6–7]. В рамках ИЭИ-технологии важным параметром обучения СППР является уровень селекции координат двоичных эталонных векторов-реализаций образа [6], определяющий геометрические центры замкнутых разделяющих гиперповерхностей — контейнеров классов распознавания при их восстановлении в радиальном базисе пространства признаков распознавания. При этом оптимизация уровней селекции позволяет в соответствии с максимально-дистанционным принципом повысить среднее межклассовое расстояние для классов распознавания. В работах [6–8] исследовалось влияние уровня селекции координат двоичных эталонных векторов-

реализаций образов на функциональную эффективность обучения СППР в процессе его оптимизации по параллельному алгоритму, предусматривающего одновременное изменение уровней квантования признаков распознавания, что, в общем случае, не обеспечивает высокую достоверность распознавания реализаций в режиме экзамена.

В статье рассматривается информационно-экстремальная оптимизация уровней селекции координат двоичных эталонных векторов-реализаций образов по параллельно-последовательному алгоритму.

Постановка задачи

Рассмотрим формализованную постановку задачи информационного синтеза СППР в рамках ИЭИ-технологии. Заданы алфавит классов распознавания $\{X_m^o / m = \overline{1, M}\}$, характеризующих M функциональных состояний патологического процесса и априорно классифицированная обучающая матрица типа «объект-свойство», $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, где N , n — количество признаков распознавания и реализаций образа соответственно. Кроме того, известен вектор параметров обучения СППР $g = \langle x_m, d_m, \delta, \rho_m \rangle$, который состоит из эталонной реализации x_m класса X_m^o , параметра d_m — кодового расстояния гиперповерхности контейнера K_m^o класса X_m^o от вершины эталонной реализации $x_m \in X_m^o$, параметра поля контрольных допусков $\delta \in [0; \delta_H / 2]$, где δ_H — нормированное (эксплуатационное) поле допусков на признаки распознавания и уровень селекции ρ_m координат эталонной реализации x_m , $\rho_m \in [0; 1]$. Заданы допустимые области значений параметров: $x_m \in \Omega_B^{[N]}$, где $\Omega_B^{[N]}$ — бинарное пространство признаков мощности N и $d_m \in [0; d(x_m \oplus x_c) - 1]$, где x_c — эталонная реализация соседнего (ближайшего) к X_m^o класса X_c^o .

Необходимо в процессе обучения системы определить оптимальные значения координат вектора параметров функционирования, обеспечивающих максимальное значение усредненного по алфавиту критерия функциональной эффективности (КФЭ) обучения системы распознавания:

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{\{k\}} E_m, \quad (1)$$

где E_m — информационный КФЭ обучения СППР распознавать реализации класса X_m^o , $\{k\}$ — упорядоченное множество шагов обучения (восстановления контейнеров классов распознавания).

На этапе экзамена необходимо с максимальной достоверностью принять решение о принадлежности реализации распознаваемого образа к одному из классов алфавита X_m^o .

Алгоритм обучения СППР

Оптимизацию уровней селекции координат эталонных векторов классов распознавания будем осуществлять по параллельно-последовательному алгоритму, при котором определенный по результатам параллельной оптимизации квазиоптимальный уровень селекции принимается для процедуры последовательной оптимизации как стартовый. Алгоритм обучения СППР в рамках ИЭИ-технологии представим как многоциклическую итерационную процедуру поиска глобального максимума информационного КФЭ (1) в рабочей (допустимой) области определения его функции. При этом оптимальный уровень селекции координат эталонных векторов определяется в результате реализации алгоритма

$$\rho^* = \arg \max_{G_\rho} \{ \max_{G_\delta} \{ \max_{G_\Omega \cap G_{d_m}} \bar{E}^* \} \}, \quad (2)$$

где G_ρ — область допустимых значений параметра ρ ; G_δ — область допустимых значений параметра поля допусков δ ; G_Ω — область допустимых значений признаков распознавания; G_{d_m} — область допустимых значений параметра d_m .

При этом внутренний цикл алгоритма (2) реализует алгоритм параллельной оптимизации системы контрольных допусков на признаки распознавания.

Рассмотрим алгоритм параллельной оптимизации уровня селекции координат эталонных векторов, который восстанавливает в процессе обучения оптимальные контейнеры классов распознавания. Входные данные: массив реализаций образа $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$ и система нормированных допусков $\{\delta_{H,i}\}$, которая определяет область значений соответствующих контрольных допусков на признаки распознавания, и уровень селекции ρ координат эталонной реализации x_m . Областью значений параметра δ принимается интервал $[0; \delta_H / 2]$, областью значений параметра ρ — интервал $\rho \in [0; 1]$.

Рассмотрим основные этапы реализации алгоритма:

1. Устанавливаются значения для верхнего ρ_v и нижнего ρ_n значения уровня селекции соответственно.
2. Устанавливается шаг изменения уровня селекции $\rho_c = 0,02$.
3. Устанавливается значение текущего уровня селекции $\rho_z = \rho + \rho_c$.
4. Выполняется алгоритм параллельной оптимизации системы контрольных допусков на признаки распознавания [9], внутренний цикл которого реализует базовый алгоритм обучения системы распознавания:
 - 4.1. Формируется бинарная обучающая матрица $\|x_{m,i}^{(j)}\|$ по правилу

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } A_{HK_i}[l] < y_{m,i}^{(j)} < A_{BK_i}[l]; \\ 0, & \text{else,} \end{cases}$$

где $A_{HK_i}[l]$ и $A_{BK_i}[l]$ нижние и верхние контрольные допуски для i -го признака эталонного вектора-реализации y_1 базового класса X_1^o , который характеризует наиболее предпочтительное для лица, принимающего решение, функциональное состояние СППР.

4.2. Формируется множество $\{x_m\}$ эталонных векторов-реализаций классов распознавания по правилу

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho z; \\ 0, & \text{else.} \end{cases}$$

4.3. Осуществляется разбиение множества $\{x_m\}$ на пары ближайших эталонных векторов.

4.4. Для каждого класса распознавания восстанавливается контейнер по схеме:

- а) обнуляется счетчик классов распознавания $m := 0$;
- б) изменяется счетчик классов распознавания: $m := m + 1$;
- в) обнуляется значение радиуса контейнера $d := 0$;
- г) изменяется значение радиуса контейнера: $d := d + 1$;
- д) вычисляется значение информационного КФЭ (1);
- е) если $E_m \notin G_E$, то выполняется п. 4.4., подп. г, иначе — п. 4.4., подп. ж;
- ж) выполняется процедура поиска максимума КФЭ (1) в рабочей области

определения его функции: $E_m^*[\rho z] := \underset{\{d\}}{\text{extrem}} E_m[\rho z, d]$;

з) определяется оптимальный радиус контейнера класса X_m^o :
 $d_m^*[\rho z] := \arg \underset{\{d\}}{\text{extrem}} E_m[\rho z, d]$.

и) если $m \leq M$, то выполняется п. 4.4., подп. б, иначе — п. 5.

5. Если $\rho z < \rho v$, то выполняется п. 3, иначе — п. 6.

6. Выполняется процедура поиска глобального максимума КФЭ:
 $\bar{E}^* := \underset{\{\rho\}}{\text{extrem}} \bar{E}^*[\rho z]$.

7. Определяется оптимальное значение уровня селекции: $\rho^* := \arg \bar{E}^*$.

8. Реализуется алгоритм последовательной оптимизации системы контрольных допусков на признаки распознавания, который в рамках ИЭИ-технологии имеет вид структурированной многоциклической итерационной процедуры:

$$\{\delta_{K,i}^*\} = \arg \left[\otimes_{s=1}^S \max_{G_{\delta_i}} \{ \max_{G_E \cap G_d} \bar{E}^{(s)} \} \right], \quad i = \overline{1, N}, \quad (3)$$

где $\bar{E}^{(s)}$ — усредненный КФЭ обучения СППР, вычисленный на s -й итерации последовательной процедуры; G_{δ_i}, G_E, G_d — области допустимых значений контрольных допусков для i -го признака, критерия оптимизации и радиусов контейнеров соответственно; \otimes — символ операции повторения.

В процедуре (3) внутренний цикл оптимизации на каждой s -й итерации реализует базовый алгоритм обучения СППР. При этом определенные по результатам параллельной оптимизации квазиоптимальные контрольные допуски на признаки распознавания при оптимальном значении уровня селекции ρ^* принимаются для процедуры последовательной оптимизации как стартовые, что обеспечивает нахождение значений информационного КФЭ в рабочей области определения его функции.

9. Реализуется алгоритм последовательной оптимизации уровней селекции $\{\rho_m\}$ координат эталонных векторов-реализаций, который в рамках ИЭИ-технологии имеет вид структурированной двухциклической итерационной процедуры:

$$\{\rho_m^*\} = \arg \left[\otimes_{s=1}^S \max_{G_{\rho_m}} \{ \max_{G_{\Omega} \cap G_{d_m}} \bar{E}^{(s)} \} \right], \quad m = \overline{1, M}, \quad (4)$$

где $\bar{E}^{(s)}$ — усредненный КФЭ обучения СППР, вычисленный на s -й итерации последовательной процедуры; $G_{\rho_m}, G_{\Omega}, G_{d_m}$ — области допустимых значений параметра ρ_m для m -го класса, признаков распознавания и параметра d_m ; \otimes — символ операции повторения.

В процедуре (4) внутренний цикл оптимизации реализует базовый алгоритм обучения СППР при оптимальной системе контрольных допусков на признаки распознавания. При этом определенный по результатам параллельной оптимизации квазиоптимальный уровень селекции ρ^* принимается для процедуры последовательной оптимизации как стартовый.

10. Завершение работы алгоритма обучения СППР.

В качестве критерия оптимизации параметров обучения в рамках ИЭИ-технологии может рассматриваться любая статистическая информационная мера, являющаяся функционалом от точностных характеристик. Например, для двухальтернативных решений и равновероятных гипотез применим рабочую модификацию критерия Кульбака [6]:

$$E_m^{(k)} = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_{2,m}^{(k)} + K_{3,m}^{(k)}]}{[K_{2,m}^{(k)} + K_{3,m}^{(k)}] + 10^{-r}} \right\} [n - (K_{2,m}^{(k)} + K_{3,m}^{(k)})], \quad (5)$$

где $K_{1,m}^{(k)}$, $K_{2,m}^{(k)}$ — количество событий, означающих принадлежность или непринадлежность реализаций образа контейнеру $K_{m,k}^o$, при условии, что они принадлежат классу X_m^o ; $K_{3,m}^{(k)}$, $K_{4,m}^{(k)}$ — количество событий, означающих принадлежность или непринадлежность реализаций образа контейнеру $K_{m,k}^o$ при условии, что они принадлежат классу X_2^o ; k — шаг обучения системы распознавания; n — минимальный объем репрезентативной обучающей выборки, r — число цифр в мантиссе значение критерия $E_m^{(k)}$.

Пример реализации алгоритма обучения СППР

Входными данными являются обучающие матрицы для трех классов распознавания, характеризующих различные стадии патологии острой клинической инфекции (ОКИ), вызванной условно-патогенными микроорганизмами. При этом класс X_1^o характеризует контрольную группу лиц (здоровые лица). Класс X_2^o — группу пациентов, для которых необходима комбинированная схема лечения с включением коллоидного серебра (10 мг/л) и класс X_3^o — группу пациентов, для которых необходимо одновременное назначение пробиотика и коллоидного серебра на фоне базисной терапии. Обучающие матрицы имели по 40 реализаций, каждая из которых состояла из 19 признаков распознавания, полученных по результатам лабораторных исследований микробиоценоза кишечника, уровня секреторного IgA, противовоспалительного цитокина IL 1 β , противовоспалительного цитокина IL 4, интегративных показателей эндогенной интоксикации.

Согласно максимально-дистанционному принципу теории распознавания образов одним из путей повышения функциональной эффективности обучения системы является увеличение межцентровых кодовых расстояний. С этой целью в рамках ИЭИ-технологии была проведена на этапе обучения по процедуре (2) параллельная оптимизация уровня селекции координат эталонных векторов-реализаций классов распознавания.

График зависимости усредненного значения КФЭ для заданного алфавита классов распознавания от значения уровня селекции ρ показан на рис. 1.

На рис. 1 темные участки графика обозначают рабочую (допустимую) область определения функции (5), в которой значения первой и второй достоверностей превышают соответственно ошибки первого и второго рода. Поскольку на рис. 1 максимальные значения КФЭ находятся на участке графика типа «плато», то выбор оптимального значения уровня селекции ρ^* осуществим с учетом изменения коэффициента нечеткой компактности [6]

$$l_{cp} = \frac{1}{M} \sum_{m=1}^M \frac{d_m^*}{d(x_m \oplus x_{c,m})}, \quad (6)$$

где $x_{c,m}$ — эталонный вектор класса X_c^o , ближайшего к классу X_m^o .

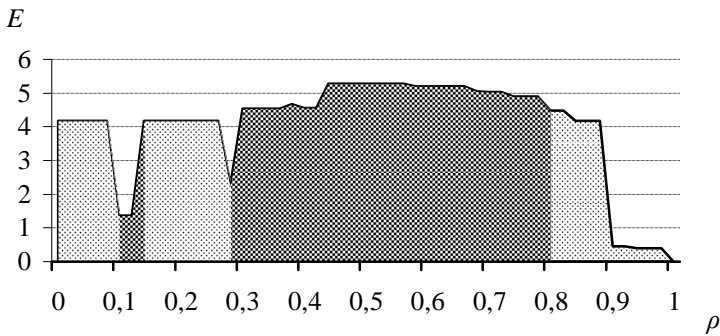


Рис. 1 График зависимости усредненного значения КФЭ от значения уровня селекции

Проведенный анализ коэффициента (6), вычисленного на участке типа «плато» для максимальных значений КФЭ (рис.1), показал, что он принимает минимальное значение при оптимальном уровне селекции $\rho^* = 0,5$ и оптимальном значении параметра поля контрольных допусков $\delta^* = \pm 64\%$ от номинального (усредненного) значения соответствующего признака. При этом усредненное максимальное значение КФЭ равняется $\bar{E} = 5,28$, оптимальные радиусы контейнеров классов распознавания: для класса X_1^o — $d_1^* = 4$, для класса X_2^o — $d_2^* = 2$ и для класса X_3^o — $d_3^* = 3$, а межцентровые расстояния между парами ближайших классов — $d(x_1 \oplus x_2) = 8$, $d(x_2 \oplus x_3) = 4$ и $d(x_3 \oplus x_1) = 4$.




Рис. 2. График зависимости критерия Кульбака от количества итераций алгоритма обучения СППР

На рис. 2 приведен график зависимости усредненного по алфавиту классов распознавания КФЭ от количества прогонов (итераций) s алгоритма обучения СППР (3), полученный в процессе параллельно-последовательной оптимизации контрольных допусков на признаки распознавания при оптимальных значениях уровня селекции $\rho^* = 0,5$ и параметра поля

контрольных допусков, равном $\delta^* = \pm 64\%$ от номинальных значений признаков.

Анализ рис. 2 показывает, что уже на третьей итерации алгоритма последовательной оптимизации системы контрольных допусков на признаки распознавания получено максимальное усредненное значение КФЭ, которое равно $\bar{E}^* = 6,54$. На рис. 3 показаны графики зависимости КФЭ (5) от радиусов гиперсферических контейнеров классов распознавания, полученных при оптимальных уровнях селекции $\rho_m, m = \overline{1, M}$.

Анализ рис. 3 показывает, что усредненное максимальное значение КФЭ равно $\bar{E}^* = 6,54$. При этом оптимальные радиусы контейнеров классов распознавания равняются $d_1^* = 2$ для класса X_1^o , $d_2^* = 3$ для класса X_2^o и $d_3^* = 3$ для класса X_3^o , а межцентровые расстояния между парами ближайших классов — $d(x_1 \oplus x_2) = 6$, $d(x_2 \oplus x_1) = 4$ и $d(x_3 \oplus x_2) = 4$.

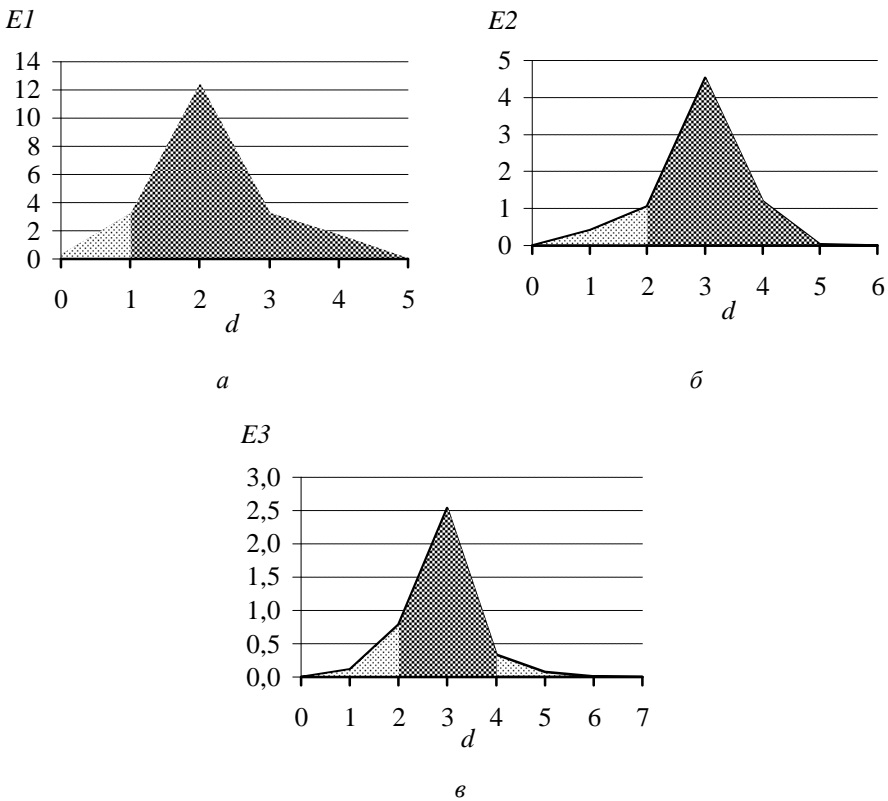


Рис. 3. Графики зависимости критерия Кульбака от радиусов гиперсферических контейнеров классов распознавания: a — класс X_1^o ; b — класс X_2^o ; $в$ — класс X_3^o

Для данного примера была проведена оптимизация уровней селекции $\rho_m (m = \overline{1, M})$ координат эталонных векторов-реализаций классов распознавания по алгоритму (4). В результате получены аналогичные

значения параметров, что можно рассматривать как частный случай.

В режиме экзамена решение принималось путем определения максимального значения геометрической функции принадлежности, которая для гиперсферического классификатора и реализаций класса X_m^o имеет вид

$$\mu_m = 1 - \frac{d(x_m^* \oplus x_e)}{d_m^*},$$

где x_e — вектор-реализация образа, который распознается.

По результатам физического моделирования в режиме экзамена СППР подтверждена работоспособность и надежность разработанного информационного и программного обеспечения.

Выводы

1. Разработанный информационно-экстремальный алгоритм машинного обучения СППР для диагностирования ОКИ по априорно классифицированной обучающей матрице позволяет определить оптимальные уровни селекции координат эталонных векторов — реализаций образов, что обеспечивает повышение достоверности диагностирования.

2. Для построения безошибочных по обучающей матрице решающих правил целесообразна оптимизация других параметров функционирования СППР и переход на иерархическую структуру алгоритмов обучения и экзамена, что актуально при увеличении мощности алфавита классов распознавания.

1. Литвин А.А. Система поддержки принятия решения в прогнозировании и диагностике инфицированного панкреонекроза / А.А. Литвин, О.Г. Жариков, В.А. Ковалев // Врач и информационные технологии. — 2012. — № 2. — С. 54–63.
Litvin A.A., Jarikov O.G., Kovalev V.A. Clinical Decision Supports System in Prediction and Diagnosis of Infected Pancreatic Necrosis. *Physician and Information Technology*, 2012, no. 2, pp. 54–63.
2. Lamma E., Mello P., Riguzzi F., Storari S., Valastro G. Artificial Intelligence Techniques for Monitoring Dangerous Infections. *IEEE Transactions on Information Technology in Biomedicine*, 2006, no. 10 (1), pp.143–155.
3. Васильев В.И. Распознающие системы. Справочник. 2-е изд., перераб. и доп. / В.И. Васильев. — К. : Наукова думка, 1983. — 422 с.
Vasilyev V.I. *Recognition Systems*. Handbook. Ed. 2, revised and enlarged. Kyiv: Naukova Dumka, 1983. 422 p.
4. Прикладная статистика: Классификация и снижение размерности. Справ. изд. / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин / Под ред. С.А. Айвазяна. — М. : Финансы и статистика, 1989. — 607 с.
Aivazyan S.A. Buchshtaber V.M., Yenyukov I.S., Meshalking L.D. *Applied Statistics: Classification and Dimension Reduction*. Moscow: Finance and Statistics, 1989. 607 p.
5. Турбович И.Т. Опознание образов. Детерминированно-статистический подход / И.Т. Турбович, В.Г. Гитис, В.К. Маслов. — М. : Наука, 1971. — 246 с.
Turbovich I.T. Gitis V.G., Maslov V.K. *Pattern Recognition. Deterministic and Stochastic Approach*. Moscow: Nauka, 1971. 246 p.
6. Довбиш А.С. Основи проектування інтелектуальних систем : Навчальний посібник / А.С. Довбиш. — Суми: Видавництво СумДУ, 2009. — 171 с.
Dovbysh A.S. *Intelligent Systems Fundamentals Design: Tutorial*. Sumy: SSU Publisher, 2009. 171 p.

7. Барило К.В. Оптимізація рівнів селекції координат еталонних векторів при розпізнаванні електронограм / К.В. Барило // Біоніка інтелекту. — 2011. — № 3 (77). — С. 107–111.
Barylo K.V. Optimization of Reference Vectors Coordinates' Selection Level in Electron Diffraction Recognition. *Bionics of Intelligence: Sci. Mag.*, 2011, no. 3 (77), pp. 107–111.
8. Барило К.В. Алгоритм оптимізації рівня селекції координат еталонних векторів класів розпізнавання / К.В. Барило // Інтелектуальні системи в промисловості і освіті: тези доповідей Третьої міжнародної науково-практ. конф., — Суми : СумДУ, — 2011. — Т.1. — С. 12–13.
Barylo K.V. Patterns Reference Vectors Coordinates' Selection Level Optimization Algorithm. *Intelligence Systems in Industry and Education: Abstracts of Third International Scientific Conference*. Sumy: SSU, 2011, Vol. 1, pp. 12–13.
9. Довбиш А.С. Система підтримки прийняття рішень для визначення схеми лікування гострої кишкової інфекції / А.С. Довбиш, Г.А. Стадник, К.С. Полов'ян // Вісник Сумського державного університету. Серія «Технічні науки». — 2012. — №1. — С. 20–26.
Dovysh A.S., Stadnyk H.A., Polovyan K.S. Decision Support System for determination of acute enteric infection treatment. *Sumy State University Bulletin. Series "Technical Sciences"*, 2012, no. 1, pp. 20–26.

Получено 02.04.2013