

УДК 658.512.011

## МЕТОДЫ ОБРАБОТКИ ИЗОБРАЖЕНИЙ МИКРООБЪЕКТОВ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ И БАЗЫ ЗНАНИЙ С МАТРИЦАМИ ИМПЛИКАЦИЙ

*Жуманов И.И.*

Сформулирована проблема совершенствования и развития методологии идентификации и оптимальной обработки изображений микрообъектов. Предложены подходы к синтезу статистических, динамических, нейросетевых моделей, а также принципы адаптивного обучения рекуррентной нейронной сети на основе БЗ с матрицами импликаций и настройки. Решены задачи оптимальной обработки данных путем редуцирования избыточных связей в переменных, сжатия и использования статистических параметров, динамических, специфических характеристик изображений объектов, а также особенностей НС. Построены модифицированные вычислительные схемы регулирования параметров компонентов и алгоритмов обучения НС на основе использования механизмов настройки переменных и формирования оптимального набора обучающих данных. Разработан программный комплекс для распознавания и классификации изображений микроорганизмов в составе крови, а также проведен анализ результатов экспериментальных исследований.

**Ключевые слова:** микрообъекты, изображения, идентификация, обработка данных, свойства данных, нейронная сеть, регулирование, адаптация, оптимизация, программный комплекс, распознавание и классификация.

Микрообъект тасвирларини идентификация қилиш ва мақбул ишлов бериш услубиятини такомиллаштириш ва тараққий қилиш муаммоси талқин этилган. Статистик, динамик, нейротармоқ моделлар синтезига ёндашув, ҳамда импликацияли матрица ва созлаш қоидаларига эга билимлар базаси асосида рекуррент нейрон тармоғини (НТ) адаптив ўргатиш принциплари таклиф қилинган. Ўзгарувчиларда ортиқ боғлашларни редукциялаш, қисиш ва объект тасвирлари статистик параметрлари, динамик, хусусий таснифлари ҳамда НТ хусусиятлари бўйича маълумотларга мақбул ишлов бериш масалалари ечилган. Созлаш ва маълумотларни ўргатувчи танламаларини мақбул шакллантириш, НТ компонентлари ҳамда ўргатиш алгоритмларининг ўзгарувчиларни созлаш механизмлари асосида такомиллаштирилган ҳисоб схемалари қурилган. Қон таркибидаги микроорганизмлар тасвирларини таниш ва синфлаштириш учун дастурий мажмуа яратилган ҳамда тажрибавий тадқиқот натижалари таҳлили қилинган.

**Таянч иборалар:** микрообъект, тасвир, идентификация, ахборотни кайта ишлаш, маълумот хоссалари, нейрон тармоғи, мувофиқлаштириш, мослаш, мақбуллаштириш, дастурий мажмуа, таниш ва синфлаштириш.

A topical research was carried out with aim to develop the methods for identifying and processing the data on the basis of fundamentally new approaches to solving the problems of microobjects images visualization, recognition and classification. Relevance of the research related with modeling of non-stationary objects, characterized by a large number of variables, strong variations of random time series (RTS), presence of redundancy, little informative elements is substantiated by problems solving in conditions of limited a priori information, parametric uncertainty, inaccuracy of data that are not taken into account in traditional methods of processing. The effectiveness of data processing tools is enhanced by use the mechanisms for extracting statistical parameters, dynamic properties of information, specific characteristics, hidden patterns, relationships between variables. Databases (DB) and knowledge bases (KB), formed for identification of microobjects, provide a wide opportunity for constructing the variables adaption mechanisms and interesting applications.

The designed computing schemes of NN are endowed with new methods which able to cope inaccuracy of data processing without loss of performance, conform to real examples, and also adapt well to the conditions of using typical algorithms, applied software packages intended for intelligent computing. The proposed approaches are aimed to saving the user from using many iterative algorithms with time-consuming calculations caused by a large number of variables, complex structure of models for identifying a dynamic object. Methodical bases are developed for improving the methods and algorithms for identifying of microobject image, the computational scheme of NN learning on the basis of using a recurrent network, as well as the KB of implication matrices for variables adjusting during solve the problems of microorganisms recognition and classification.

A three-layer NN model is recommended for practical implementation, and it is synthesized with adequate model for microobject images identifying, adaptive network learning algorithm and algorithm of optimization based on conjugate gradient method. The generalized algorithm which combines possibilities of cubic splines is implemented for image identification and programmed algorithmic complex is realized for recognition and classification of unicellular microorganisms in the blood. The complex operates on the basis of created application software. The complex architecture is open and represents the hierarchical structure of connection, and is also developed using Builder C ++ tools.

**Key words:** microobjects, images, identification, data processing, data properties, neural network, regulation, adaptation, optimization, software complex, recognition and classification.

## I. ВВЕДЕНИЕ

**Актуальность темы.** В настоящее время остро востребованы результаты исследования, направленного на разработку методов идентификации и обработки данных на основе принципиально новых подходов для решения задач визуализации, распознавания и классификации изображений микрообъектов, в частности пылевых зерен, одноклеточных микроорганизмов, отпечатков пальцев, изображений полезных минералов в горной массе [1].

Объекты идентификации характеризуются сложностью структуры, разнотипностью компонентов, многосвязанностью переменных, нестационарностью процессов представления, вследствие чего требуемые математические описания проводятся с большой погрешностью, а модели имеют лишь частичную истинность [2].

В существующих системах, методах, технологиях обработки изображений для идентификации все шире применяются стохастические, динамические модели, задаваемые алгебраическим полиномом, сплайн-функцией, вейвлет-анализом, сглаживающим фильтром, которые при решении прикладных задач требуют расширенную априорную информации, сведений о свойствах, особенностях и характеристиках объектов. Методы при этих моделях становятся пригодными только в тех условиях, когда задается параметрическое описание контура изображения и фактор неопределенности отсутствует.

В работе [3] актуальность исследования, связанного с моделированием нестационарных объектов, характеризующихся большим количеством переменных, сильными вариациями динамики случайных временных рядов (СВР), наличием избыточности, малоинформативных элементов обосновывается по решениям задач идентификации изображения в условиях ограниченности априорных сведений, параметрической неопределенности, неточности представления данных, которые не учитываются в традиционных подходах и методах обработки данных.

В качестве перспективного направления проводимого исследования для совершенствования существующих методов и разработки новых технологий идентификации и обработки изображений микрообъектов считается применение математического аппарата компонентов мягких вычислений, в частности, нейронных сетей (НС) [4].

Особенностями инструментария НС являются эффективность использования механизмов извлечения статистических параметров, динамических свойств информации, специфических характеристик, полезных свойств, скрытых закономерностей, взаимосвязей между переменными [5]. Базы данных (БД) и базы знаний (БЗ), формируемые для идентификации микрообъектов дают широкую возможность при построении

механизмов адаптации переменных, мало итеративных алгоритмов, интересных приложений для решения проблемных задач благодаря уникальным свойствам НС [6-8].

Предлагаемый подход к решению задач на основе интеллектуальных технологий анализа способствует избавлению пользователя от применения много итеративных алгоритмов с трудоемкими вычислениями в решениях задач с большим числом переменных, сложной структурой моделей идентификации, динамичностью объекта в конкретных случаях и реальном режиме времени. В связи с этим, проектируемые системы визуализации, распознавания и классификации изображений микрообъектов на основе НС должны быть наделены новыми методами, способными справляться с неточностью обработки данных без потери производительности, согласовываться с реальными примерами, а также хорошо адаптироваться к условиям использования типичных вычислительных схем, алгоритмов, прикладных пакетов программ, предназначенных для интеллектуальных вычислений [4].

Настоящая работа посвящена исследованию методических основ совершенствования и разработки методов и алгоритмов идентификации, обработки изображения микрообъекта, вычислительной схемы обучения НС, а также эффективности моделей на базисе использования рекуррентной сети, БЗ матриц импликаций, механизмов настройки переменных при решении задач распознавания и классификации микроорганизмов в составе крови путем обширного анализа экспериментальных результатов.

## II. ОСНОВНАЯ ЧАСТЬ

**Основные задачи совершенствования и развития методологии идентификации изображений микрообъектов.** Большую значимость представляют методы оптимизации обработки изображений микрообъектов на основе результатов следующих исследований [6,7]:

- построение механизмов извлечения и редуцирования избыточных связей между переменными компонентами в сложной структуре модели, сжатия размера признакового пространства описания объектов, уменьшения размера задач, устранения малозначимых и неинформативных переменных на основе разработки статистических, динамических, нейросетевых подходов;
- проектирование алгоритмов адаптивного обучения НС, использующих статистические параметры, динамические, специфические характеристики изображений микрообъектов, скрытых и полезных свойств, закономерностей в данных, а также особенностей сети;
- проектирование модифицированных вычислительных схем компонентов НС, механизмов, направленных на регулирование параметров, формирование оптимального набора обучающих данных,

адекватное описание контура изображения микрообъекта, а также обучения сети различной топологии;

- разработка методов обнаружения, корректировки искаженных элементов изображения микрообъекта при условиях непрерывного изменения факторов и влияния параметра внешней среды;
- разработка методов идентификации СВР на основе совмещения возможностей различных моделей НС, стохастических и динамических моделей, адекватно описывающих контур изображения микрообъекта.

Показателем результативности методов, оптимизирующих обработку данных является устранение проблематичности в поиске комбинаторного типа, характерного традиционной системе поэлементной обработки данных, при которой обычно происходит просмотр поисковых признаков при  $\frac{n!}{2n}$  различных вариантах [1].

**Основные подходы и принципы оптимизации идентификации изображений микрообъектов.** В статистических подходах к редуцированию избыточных связей между переменными компонентом модели идентификации решаются задачи сжатия признаков пространства описания объекта, уменьшения размера задач, строятся механизмы выявления малозначимых переменных и неинформативных признаков за счет использования коэффициентов авто-, взаимно-, парных корреляций [6].

В [5] разработана методика реализации стохастической модели отбора информативных признаков на основе коэффициентов влияний и эластичности факторов.

Динамический подход к отбору информативных признаков направлен на применение широкого спектра моделей сглаживания изображений объектов, основанных на алгебраические полиномы, параболических и кубических сплайн-функций, вейвлет-анализа пятого порядка, линейный и нелинейных фильтров нестационарных процессов [7].

В работе [6] при нейросетевом подходе к отбору информативных признаков оптимизация идентификации изображений микрообъектов выполняется на основе алгоритмов адаптивного обучения НС и модифицированных вычислительных схем компонентом сети.

Модификация вычислительных схем компонентом многослойной НС проводится в двух этапах. На первом этапе реализованы типичные схемы определения весовых коэффициентов нейронов, выбора подходящей активационной функции, расчета коэффициентов синаптических связей. А на втором этапе решены задачи проектирования рациональной архитектуры НС с определением рационального числа слоев и нейронов в слоях сети, а также определяются нелинейные функциональные зависимости «входы – выходы». Исследованы различные модели обучения НС. Реализованы алгоритмы обучения сети с прямонаправленным и обратным распространением ошибок,

которые оптимизируются на основе методов наименьших квадратов, градиентного поиска, а также сопряженных градиентов.

Определено, что традиционным методам обучения НС характерна необходимость вычисления точных значений градиента, которые не всегда доступны. В нередких случаях обучение НС выполняется в условиях большой размерности пространства признаков решаемых задач. А работа алгоритмов формирования наборов обучающих данных, как правило, связана с высокой чувствительностью к изменениям их размерности, обусловлена трудоемкими процедурами поиска глобального и локальных экстремумов.

В [7] для совершенствования вычислительных схем обучения НС предлагаются два подхода. Первый подход, направлен на формирование наборов обучающих данных рациональных размеров, применение вероятностных методов идентификации и аппроксимации, использование свойств, особенностей изображений микрообъектов и НС.

Второй подход, направлен на конструирование вычислительных схем компонентов НС на основе синтеза механизмов определения и настройки весов нейронов, коэффициентов синаптических связей, параметров активационных функций, числа слоев, нейронов в слоях и архитектуры сети. Для практической реализации рекомендована модель трехслойной НС, которая синтезируется с адекватной моделью идентификации изображений микрообъектов, а также алгоритмом адаптивного обучения сети, метода оптимизации на основе сопряженного градиента. Вычислительные схемы обучения НС при этом построены на основе совмещения алгоритмов отбора информативных признаков, сегментации контура изображения объекта, реализации эвристических алгоритмов поиска с отжигом, запретом и стохастического моделирования. Реализованы также типичные вычислительные схемы НС Хопфильда, Хемминга, Хебба, Кохенена, двухнаправленной ассоциативной памяти.

**Модифицирование вычислительной схемы обучения НС.** Для идентификации объекта синтезируется вычислительная схема поиска по маршруту на основе использования рекуррентной нейронной сети (РНС). Входная информация при этом представляется в виде специальной матрицы, в которой элементы СВР размещаются по строкам, а столбцы ее отображают последовательность действий при реализации правил алгоритма поиска.

Каждый нейрон РНС обозначается индексами  $x$  и  $i$ , где через  $x$  обозначен объект, а  $i$  указывает позицию проверяемого элемента в маршруте поиска. Через  $z_{xi}$  обозначен нейрон на выходе сети. Позиция  $(x, i)$  столбца матрицы равна «1», когда объект  $x$  занимает  $i$ -е место в маршруте поиска.

Реализация модели сети связана с формированием матрицы размером  $n \times n$  нейронов. Нейроны сети взаимодействуют по строкам и столбцам матрицы. Предложен ускоренный алгоритм обучения сети. Присутствие в модели обучения сети переменной с большими избыточными связями обуславливает выполнения десяти миллиардов комбинации поиска, что

наблюдается при наличии 10 переменных с 10 признаками у каждой переменной.

Вычислительную сложность алгоритма обучения сети необходимо снизить почти на два порядка путем уменьшения комбинаторной сложности традиционного метода оптимизации поиска со значением  $O(n^4)$  до значения  $O(n^2)$ .

Предложена методика формирования матриц импликации, правил поиска, редукции избыточных связей в переменных, которые используются при проектировании упрощенной структуры сложной модели изображения микрообъектов, мало итеративного алгоритма поиска и обучения НС.

Исследован вопрос проектирования набора обучающих данных при существенно уменьшенной избыточной структуре, упрощенных взаимосвязях и рациональном числе элементов идентифицируемой СВР.

### **Формирование БЗ матрицы импликаций для идентификации СВР.**

Для задания различимости параметров в каждой строке матрицы импликаций  $U$  отмечаются выявленные признаки в составе переменных. Матрица импликаций является целочисленной, столбцы которой сопоставляется со столбцами матрицы  $Q$ , а строки всевозможными парами переменных  $v, l$ , обозначаемых в виде  $a$  и  $b$ ,  $v \in \{1, 2, \dots, \sigma(Q^a)\}$ ,  $l \in \{1, 2, \dots, \sigma(Q^b)\}$ . Переменные  $\sigma(Q^a)$  и  $\sigma(Q^b)$  определяют количество элементов в строке подматрицы  $Q^a$  либо подматрицы  $Q^b$  в заданной матрице  $Q$ . Вектор функции различения  $u_{i,j}$  - ого элемента,  $j \in \{1, 2, \dots, m\}$  в строке подматрицы задается, как

$$u_{i,j} = |q_{v,j}^a - q_{l,j}^b|, \quad (1)$$

где  $q_{v,j}^a$  - элемент  $v$  строки матрицы импликации и  $j$  элемент заданной матрицы  $Q^a$ ;

$q_{l,j}^b$  - элемент  $l$  строки матрицы импликации и  $j$  элемент заданной матрицы  $Q^b$ .

Для оценки значимости различия  $u_{i,j}$   $j$ -ого элемента переменной задается следующее правило

$$u_{ij}^- = \begin{cases} 1, & \text{если } q_{v,j}^a; \\ 0, & \text{если } q_{l,j}^b, \end{cases} \quad (2)$$

где «1» и «0» – обозначения величины значимости функции различения.

Величина в векторе функции различия разных компонентных моделей  $a, b$  ( $a \neq b$ ), вычисляется, как

$$\delta_{a,b}^j = |q_{a,j} - q_{b,j}|, \quad (3)$$

где  $\delta_{a,b}^j$  - различие компонентов  $a$  и  $b$ ;

$q_{aj}$  - значимость влияния переменной для компоненты  $a$ .

Матрицы импликации позволяют иллюстрировать:

- представления данных и знаний, поскольку одной строкой матрицы  $Q$  можно задавать в интервальной форме подмножество значений признаков;
- различения любых пар из заданного множества;
- тестовую матрицу признаков (двоичная матрица тестов  $T$ ), столбцы которой сопоставляются со столбцом матрицы  $Q$ , а строки с диагностическим тестом.

Для описания изображения микрообъектов представляется элементы матрицы с весовым коэффициентом  $w_j$  по каждой переменной в виде

$$w_j = \frac{\sum_{r=1}^{K-1} \sum_{s=r+1}^K \sum_{a=1}^{N_r} \sum_{b=1}^{N_s} \delta_{ab}^j}{S_j \sum_{a=1}^{K-1} \sum_{b=a+1}^K \sigma_a \sigma_b} . \quad (4)$$

где  $N_r$  – число строк матрицы описания  $Q$  для  $a$ -ой компоненты;

$N_s$  – число строк матрицы описания  $Q$  для  $b$ -ой компоненты;

$K$  – число значимых признаков или переменных в компонентах  $a$  и  $b$ ;

$S_j$  – интервал изменения значений элементов в столбце матрицы  $Q$ .

Для многокомпонентного описания изображения микрообъектов задается общая матрица весов  $W_i$ , как

$$W_i = \sum_{j \in L_i} w_j .$$

**Построение механизма настройки базы знаний.** Формализованное функционирование БЗ задается кортежами

$$M = F(D, S, M_0) .$$

Модель представляется некоторой функцией, возвращающей БЗ. Аргументами функции являются набор данных  $D$ , правила настройки переменных  $S$ . Начальная (пустая) структура БЗ задается моделью  $M_0$ , не содержащей никаких закономерностей. Модель формирования набора данных  $D$  представляется кортежами

$$D(A, T, W),$$

где  $A = \{a_1, \dots, a_i, \dots, a_m\}$  - набор независимых атрибутов  $a_i$ ;

$T = \{a_{m+1}, \dots, a_k, \dots, a_t\}$  - множество целевых атрибутов;

$W = \{w_1, \dots, w_r, \dots, w_z\}$  - множество векторов данных, представляющих наборы весовых коэффициентов признаков;

$w_r = \{v_{1,r}, \dots, v_{i,r}, \dots, v_{m,r}, v_{m+1,r}, \dots, v_{k,r}, \dots, v_{m+t,r}\}$  - набор элементов  $v_{i,r} \in D(a_i)$  со значениями атрибута в векторе, соответствующие атрибуту или переменной структурной компонентной модели объекта.

Модель возвращения БЗ задается кортежами

$$M = \{R, K_t\},$$



где  $R = \{r_1, \dots, r_i, \dots, r_n\}$  – множество правил извлечения свойств данных;

$K_t = \{k_1, \dots, k_p, \dots, k_g\}$  – количество векторов;

$k_p = \left| \{w_r : w_r \in W, v_{t,r} = v_{t,p}\} \right|$  – элементы вектора целевого атрибута  $a_t$ , имеющие значение  $v_{t,p}$  в виде

$$v_{t,1} \cup \dots \cup v_{t,p} \cup \dots \cup v_{t,z} = D(t).$$

БЗ после запуска принимает одно из следующих состояний:

$M_0$  – начальное состояние;

$M_1$  – состояние после 1-го изменения;

.....

$M$  – состояние возвращенной модели.

Модель с настройкой представляется набором пар переменных, как

$$S = ((s_1, p_1), \dots, (s_y, p_y), \dots, (s_z, p_z))$$

где  $s_y, p_y$  – соответствующая пара для  $y$ -ой переменной модели.

**Алгоритм настройки структуры БЗ.** Алгоритм представляется набором последовательно выполняющихся операций, формализуемых в виде

$$F = \{O_1, \dots, O_p, \dots, O_q\},$$

где  $O_p$  – операция, изменяющая БЗ от одного состояния в другое.

Операции настройки БЗ задаются данными  $D$ , настройкой  $S$  и моделью  $M_i$ . Результат настройки БЗ  $M_{i+1}$  после изменения его состояния задается как

$$M_{i+1} = O(D, S, M_i).$$

Алгоритм настройки представляет операции

$$F = \{O_1(D, S, M_0), \dots, O_p(D, S, M_p), \dots, O_q(D, S, M_q)\}.$$

Алгоритм включает условные операторы, циклы, в том числе циклы по векторам и по данным. Условный оператор получения БЗ  $M_{i+1}$  представляется в виде

$$M_{i+1} = D(D, S, M_i) = \{d(D, S, M_i), O_t(D, S, M_i), O_f(D, S, M_i)\},$$

где  $d(D, S, M_i)$  – условная функция, возвращающая значение «истина» или «ложь» на основании данных  $D$ , текущей БЗ  $M_i$ ;

$O_t(D, S, M_i)$  – операция, выполняющая возвращение функции  $d(D, S, M_i)$  при значении «истина»;

$O_f(D, S, M_i)$  – операция, выполняющая возвращение функции  $d(D, S, M_i)$  при значении «ложь».

Цикл алгоритма представляется, как

$$M_{i+1} = C(D, S, M_i) = \{d(D, S, M_i), O_c(D, S, M_i)\},$$

где  $O_c(D, S, M_i)$  – операция, выполняющаяся пока условная функция  $d(D, S, M_i)$  возвращает значение «истина».

Упорядоченная последовательность функциональных блоков алгоритма настройки представляется как

$$M_q = F(M_0, S, D) = (b_0(D, S, M_0), \dots, b_k(D, S, M_k), \dots, b_q(D, S, M_{q-1})).$$

В [6] исследована эффективность алгоритмов сглаживания изображений микрообъектов алгебраическими полиномами, параболическими, кубическими интерполяционными и экстраполяционными сплайн-функциями, линейными и нелинейными сглаживающими фильтрами в среде параллельных вычислений CUDA.

В [7] разработаны и реализованы обобщенные алгоритмы идентификации изображений, которые объединяют возможности кубических сплайнов в программно алгоритмическом комплексе распознавания и классификации одноклеточных микроорганизмов в составе крови.

**Программный комплекс распознавания и классификации микроорганизмов.** В комплекс включены следующие функциональные модули: формирование двоичной матрицы импликации  $U$ ; нахождение соответствующих характеристических признаков микроорганизма; формирование строк матрицы  $Q$ , упорядочивание строк  $R'$  матриц  $Q$ ,  $U'$  и  $U$ ; вычисление весовых коэффициентов признаков, формирование двоичной матрицы  $U''$  путем замены значений всех элементов, отличных от «0» на значение «1»; формирования столбцевого покрытия из матрицы  $U''$  и тестирования.

Комплекс разработан на базе конструирования прикладных программных средств. Архитектура комплекса открытая и представляет иерархическую структуру соединения в системе, а также разработана с использованием средств Builder C++.

Главный модуль – резидентный, имеет встроенную систему команд, выполняет функции ядра. Все остальные модули являются динамически подключаемыми и подразделяются на функциональные модули, модули системных данных и модуль пользовательского интерфейса.

Первый модуль предназначен для работы с БД и БЗ. Выходными данными модуля являются структура БЗ, объекты базы знаний, название признаков и номера признаков. Второй модуль предназначен для выбора элементов столбцевого покрытия из матрицы  $U''$ . Третий модуль формирует номера целочисленных характеристических признаков, номера целочисленных классификационных признаков, структуру БЗ, номера выбранных обучающих объектов. Выходными данными этого модуля являются вектор номеров выбранных характеристических признаков, минимальные и максимальные значения этих признаков. Четвертый модуль предназначен построению матрицы  $U'$ , в котором используются следующие входные параметры: целочисленные матрицы  $Q$  и  $U$ , вектор номеров характеристических признаков, а также вектора минимальных и максимальных значений этих признаков. В результате исполнения модуля

формируются выходные значения, содержащие вещественный вектор весовых коэффициентов характеристических признаков и двоичную матрицу  $U''$ , являющуюся входными параметрами для модуля поиска.

### III. ЗАКЛЮЧЕНИЕ

**Экспериментальные результаты.** Алгоритм оптимальной обработки изображений реализован в виде программного модуля редукции неинформативного признакового пространства микроорганизма. Исследование проведено по данным задач анализа симптомов микроорганизмов некоторых болезней в человеческих органах.

Доказано, что сокращение признакового пространства позволит сократить число выявляемых значений характеристических признаков для новых исследуемых объектов, а также сократить временные и стоимостные затраты, исследовать и построить диагностических тестов распознавания изображений микроорганизмов по характеристическим признакам [8].

Для тестирования комплекса сформированы обучающие выборки из 40 характеристических признаков, каждая из которых включает 352 обучающих примеров, разбитых на 5 классов. При этом размер матрицы  $Q$  равен  $352 \times 40$ , а размер матрицы  $R$  равен  $352 \times 1$ . Количество характеристических признаков в исследуемых объектах равно 165. Размер матрицы  $Q$  равен  $381 \times 165$ . Проведены исследования для выявления различного рода закономерностей в данных. В первом исследовании размер матрицы  $U'$  равен  $381 \times 2$  (762), а во втором – размер матрицы  $U''$  равен также  $381 \times 2$  (762). Число микрообразов каждого исследования равно 6. По первому исследованию построена матрица  $U'''$  размером  $27352 \times 165$  и выявлены следующие факты: 155 признаков являются неинформативными; 134 признака зависимы от 139 признаков; 30 признаков зависимы от 28 признаков; 23 признака зависимы от 31 признаков. В результате удаления зависимых и неинформативных признаков признаковое пространство изображения микрообъекта сократилось до 161 признака. Во втором исследовании построена матрица  $U'''$  размером  $26149 \times 165$  и выявлены следующие факты: 155 признаков является неинформативными; 30 признаков зависимы от 28 признаков; 23 признака зависимы от 31 признаков; 33 признака зависимы от 37 признаков. В результате удаления зависимых признаков пространство неинформативных признаков сократилось до 161 признака.

## ЛИТЕРАТУРА

- [1] Загоруйко Н.Г. Прикладные методы анализа данных и знаний. - Новосибирск, 1999.- 270 с.
- [2] Алиев Р.А., Алиев Р.Р. Теория интеллектуальных систем. - Баку: Чашиоглы, 2001.-720 с.
- [3] Финн В.К. Об интеллектуальном анализе данных // Новости Искусственного интеллекта.- 2004. №3. - с. 3-18.
- [4] Хайкин Саймон. Нейронные сети: полный курс. 2-е изд./ Пер. с англ. М.: ООО «И.Д. Вильямс», 2006. – 1104 с.
- [5] Янковская А.Е. Логические тесты и средства когнитивной графики. Издательский Дом: LAP LAMBERT Academic Publishing, 2011. 92с
- [6] Жуманов И.И. Оптимизация обработки изображений микрообъектов на основе рекуррентного обучения нейронной сети и имплекативного отбора информативных признаков. Узбекский журнал «Проблемы информатики и энергетики», «Фан». – №4, 2016. - с.12-20.
- [7] Жуманов И.И., Бекмуродов З.Т. Повышение точности обработки данных нестационарных объектов на основе оптимизации набора параметров гибридной модели идентификации. XII Международная Азиатская школа-семинар «Проблемы оптимизации сложных систем», СО РАН, 12-16 декабр 2016 г., Новосибирск. – с. 192 – 201.
- [8] Жуманов И.И. Оптимизация обработки данных нестационарных объектов на основе нечетких моделей идентификации с настройкой параметров. Журнал «Вестник ТУИТ». - Ташкент, 2017. - №1(41)/2017. - с. 34-47.