

Научная статья

Статья в открытом доступе

УДК681.5.09

doi: 10.30987/2658-6436-2022-4-37-45

## МЕТОДЫ АВТОМАТИЗАЦИИ ДИАГНОСТИКИ В ПРЕДМЕТНОЙ ОБЛАСТИ

Андрей Владимирович Чирков<sup>✉1</sup>, Лариса Геннадьевна Гагарина<sup>2</sup>, Николай Сергеевич Миронов<sup>3</sup>, Роман Викторович Липовый<sup>4</sup>

<sup>1, 2, 3, 4</sup> Национальный исследовательский университет «МИЭТ», г. Москва, Россия

<sup>1</sup> andrejchirkov247@gmail.com, <sup>2</sup> gagar@bk.ru, <sup>3</sup> mniklser@yandex.ru, <sup>4</sup> Lrv.mtpp@mail.ru

**Аннотация.** В данной статье предлагается обзор некоторых из существующих методов автоматизации диагностики, применимых для разнообразных предметных областей. В настоящее время многие отрасли промышленности, медицины, сельского и агротехнического хозяйств идут по пути уменьшения необходимости участия людских ресурсов в процессах диагностики неполадок оборудования, всевозможных заболеваний как людей, так и растений. Количество всевозможных методов диагностики и методов обработки полученных данных со временем увеличивается, как и сам поток данных и требования к точности и скорости обработки. Важной задачей является построение адекватных моделей анализа данных с учетом случайных возмущений и необходимость быстрого исследования в темпе поступления данных. Единственным способом выбора наиболее оптимального метода является проведение сравнительного анализа и сопоставление множества факторов, которые необходимо учитывать при выборе того или иного метода.

**Ключевые слова:** метод диагностики, нейронные сети, матрицы смежности, сравнительный анализ, диагностика заболеваний, нечеткая логика, автоматизация диагностики

**Для цитирования:** Чирков А.В., Гагарина Л.Г., Миронов Н.С., Липовый Р.В. Методы автоматизации диагностики в предметной области // Автоматизация и моделирование в проектировании и управлении. 2022. №4 (18). С. 37-45. doi: 10.30987/2658-6436-2022-4-37-45.

Original article

Open Access Article

## DIAGNOSIS AUTOMATION METHODS IN THE SUBJECT AREA

Andrey V. Chirkov<sup>1</sup>, Larisa G. Gagarina<sup>2</sup>, Nikolay S. Mironov<sup>3</sup>, Roman V. Lipovy<sup>4</sup>

<sup>1, 2, 3, 4</sup> National Research University of Electronic Technology «MIET», Moscow, Russia

<sup>1</sup> andrejchirkov247@gmail.com, <sup>2</sup> gagar@bk.ru, <sup>3</sup> mniklser@yandex.ru, <sup>4</sup> Lrv.mtpp@mail.ru

**Abstract.** This article gives an overview of some existing diagnostic automation methods applicable to a variety of subject areas. At present, many branches of industry, medicine, agriculture and agrotechnical economies are moving towards reducing the need for involving human resources in the processes of diagnosing equipment malfunctions, various diseases of both people and plants. The number of different methods for diagnostics and processing the received data increases over time, as do the data flow itself and the requirements for the processing accuracy and speed. An important task is to build adequate models for data analysis, taking into account random perturbations and the need for rapid research at the rate of incoming data. The only way to choose the most optimal method is to conduct a comparative analysis and correlate many factors to be considered when choosing a particular method.

**Keywords:** diagnostic method; neural networks; adjacency matrices; comparative analysis; diagnosis of diseases; fuzzy logic; diagnostic automation

**For citation:** Chirkov A.V., Gagarina L.G., Mironov N.S., Lipovy R.V. Diagnosis automation methods in the subject area. Automation and modeling in design and management, 2022, no. 4 (18). pp. 37-45. doi: 10.30987/2658-6436-2022-4-37-45.

### Введение

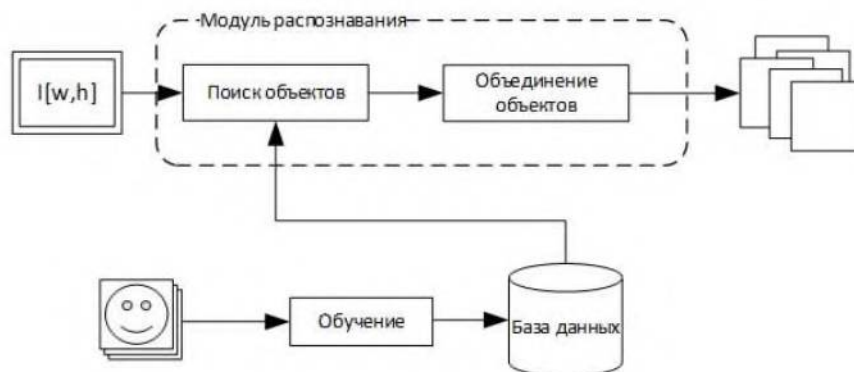
По мере роста численности населения урбанизация приведет к постепенному сокращению ресурсов Земли, а нагрузка на все виды отраслей экономики возрастёт [1]. В связи с этим и растёт спрос на методы автоматизированной диагностики работы систем и комплексов.

С течением времени в области экспертного контроля наиболее эффективным и распространённым методом стало машинное обучение. Компьютерное зрение активно используется в сельскохозяйственной области, в медицине, промышленности и т.д. Интеллектуаль-

ные системы, основанные на нейронных сетях и, в частности, на компьютерном зрении, стали повсеместно использоваться на государственных и частных предприятиях для повышения производительности [2].

### Материалы, модели, и методы

**Аналитический обзор.** Общая схема методов автоматизации диагностики на основе распознавания изображений представлена на рис. 1.



**Рис. 1.** Общая схема автоматизации диагностики на основе изображений  
**Fig. 1.** General scheme automation of image-based diagnostics

Таким образом, проблема анализа существующих методов (табл. 1) для автоматизации диагностики в различных предметных областях является актуальной и своевременной.

Таблица 1

### Сравнение методов автоматизированной диагностики

Table 1

#### Comparison of automated diagnostic methods

| Метод                                  | Описание   | Преимущества   | Недостатки   |
|--|--|--|--|
| KNN ( <i>k</i> -nearest neighbors)     | Находит ближайший наиболее встречающийся объект относительно исходного запроса   | Легкая реализация и качественный уровень распознавания   | Медленно обучается; неустойчив к зашумлённым данным при большом размере выборки  |
| SVM (support vector machine)           | Находит гиперплоскость в <i>n</i> -размерном пространстве, которая однозначно разделяет объекты на классы  | Точность прогноза высока. Надежно работает, когда пример обучения содержит ошибки              | Плохо работает, когда: выборка данных содержит много шума или большое количество данных; набор признаков на объект превышает общее количество объектов |
| PNN (probabilistic neural network)     | Работает с четырёхслойной структурой, которая включает в себя расчет расстояния, хранение переменной предиктора и сравнение голосов                | Быстрый и точный   | Требуется большое место для хранения данных  |
| ANN (artificial neural network)        | Базовая форма представлена в виде многослойного перцептрона, который обновляет вес посредством базового распространения                            | Хороший потенциал для обнаружения болезней листьев растений                                    | Требуется много времени на обучение  |
| Нечеткая логика                        | Подход, позволяющий переменным иметь несколько верных значений, описанные при помощи функции   | Высокая скорость, мало потребления оперативной памяти  | Низкая точность  |
| GLCM (gray-level co-occurrence matrix) | Статистический метод исследования текстур: как часто встречается пара пикселей с определенными значениями и с определенным расстоянием между собой | Очень высокая точность по сравнению с остальными методами, высокая скорость; легко реализуется | Медленно обучается   |

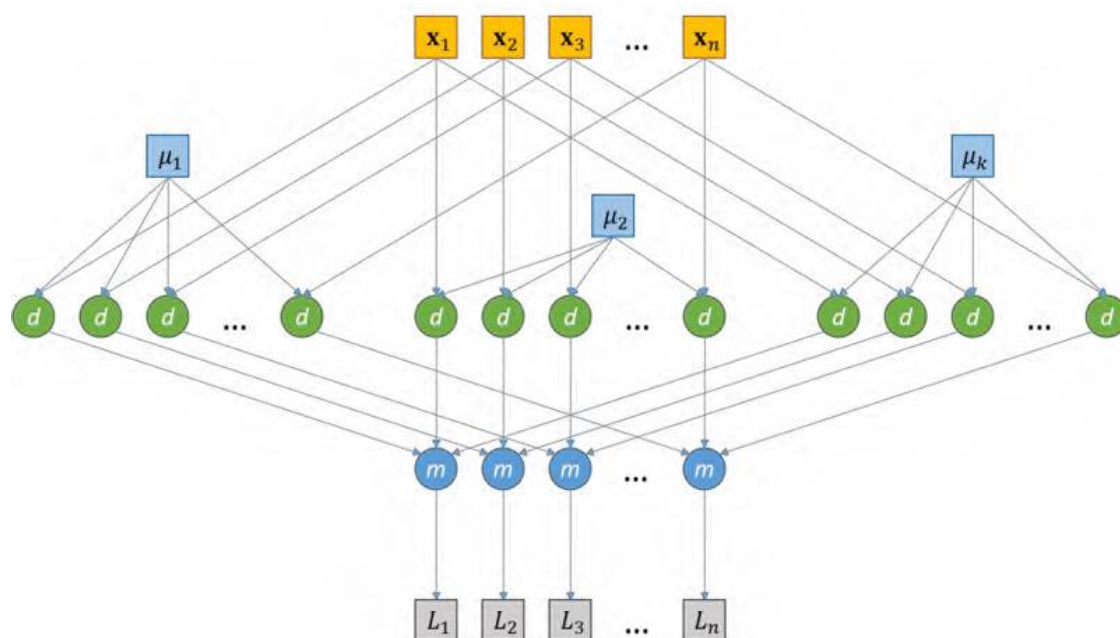
Одним из существующих подходов автоматизации диагностики по изображениям является метод распознавания на основе искусственных нейронных сетей [3]. Анализ на нейросетевых алгоритмах традиционно делится на несколько основных этапов:

- исходные данные сегментируются с использованием методов  $K$ -средних;
- из полученных на первом этапе сегментированных данных вычисляются вектора признаков, используя гистограмму направленных градиентов или масштабно-инвариантную трансформацию признаков;
- вектора признаков из предыдущего этапа передаются через переобученную искусственную нейронную сеть CNN, ANN, PNN или SVM, которая выносит решение о классификации изображений к той или иной группе отклонений.

На основе результатов, полученных авторами ранее изученных статей, делается вывод, что классификаторы искусственными нейронными сетями, основывающиеся на статистической классификации, обеспечивают автоматическое обнаружение необходимых признаков с точностью в пределах 83 – 94 % [4].

К главным методам, используемым для автоматической диагностики, относят:

1) Метод  $k$ -средних – простой классификатор методов машинного обучения, выполняющий классификацию, определяя ближайших соседей примера запроса, а затем используя этих соседей для определения класса запроса. Точка относится к классу на основе вычисления минимального расстояния между этой точкой и другими точками. В качестве классификатора ближайшие соседи не включают ни одного учебного процесса. Он не подходит, если имеется большое количество обучающих примеров, поскольку он не устойчив к зашумленным данным. Чтобы классифицировать изображения, вычисляется евклидово расстояние между обучающими образцами и тестовыми (рис. 2).



**Рис. 2. Схема распределения векторов по кластерам:**  
 $d$  – вычисление расстояния между векторами;  $m$  – вычисление минимума  
**Fig. 2. Scheme of distribution of vectors by clusters:**  
 $d$  – calculation of distance between vectors;  $m$  – calculation of the minimum

Таким образом, данный метод находит подобные показатели и, впоследствии, категории тестовых образцов. Образцы классифицируются в соответствии с наибольшим количеством голосов от их  $k$ -соседей, а выборки присваиваются к самому распространенному классу среди их  $k$ -ближайших соседей. Метод ближайшего соседа легко реализуем и работает с достаточной точностью, если функции выбираются тщательно. Классификаторы KNN удовлетворительно справляются с основными проблемами распознавания образов. Главным недостатком метода KNN является медленный алгоритм обучения. Другим серьезным недостатком является скорость работы: есть большое количество обучающих примеров, поскольку алгоритм должен вычислить расстояние и отсортировать все обучающие данные для каждого предсказания. Он также недостаточно надежен при работе с зашумленными данными. Самым серьезным недостатком KNN является то, что он чувствителен к второстепенным параметрам.

2) Метод опорных векторов (SVM) – это нелинейный классификатор. Представляет собой новую тенденцию в алгоритмах машинного обучения и используется для многих проблем в распознавании образов, включая классификацию свойств текстуры изображения. В SVM входные данные отображаются нелинейно на линейно разделенные данные в некотором многомерном пространстве, обеспечивая высокую скорость классификации. SVM максимизирует максимальное расстояние между разными классами. Использование SVM возможно только для обработки двух классов путем определения гиперплоскости для их разделения. Это делается максимизацией разрыва от гиперплоскости до двух классов. Выборки, выбранные для определения ближайшего края гиперплоскости, называют опорными векторами. Применяется также многоклассовая классификация, в основном построенная из разных SVM двух классов, решая эту проблему одним или другим способом. Категория выигрыша определяется в соответствии с наибольшим результатом или наибольшим количеством голосов.

3) Искусственный нейрон (ANN) является подобием работы человеческого нейрона (рис. 3). У каждого нейрона есть свой вес (константное значение), который меняется в процессе обучения. На входные нейроны передаются начальные значения, потом преобразуются при помощи весовых коэффициентов и суммируются, далее идет преобразование при помощи функции активации. Сеть, состоящая из нескольких слоев таких нейронов, называется многослойным персептроном. Она состоит из слоев: входной, скрытые слои (обычно от 1 до 4) и выходной. Подобную нейронную сеть обучают при помощи алгоритма обратного распространения ошибки. Многослойный персептрон является одним из самых популярных нейронных сетей, используемых для решения прикладных задач в области классификации и распознавания объектов.

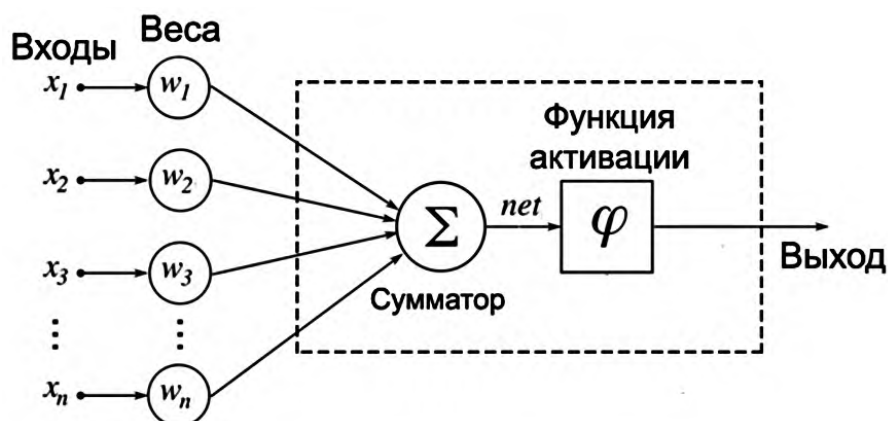


Рис. 3. Схема работы искусственного нейрона  
 Fig. 3. Scheme of an artificial neuron

4) Вероятностная нейронная сеть (PNN) является следующим этапом развития нейронных сетей. Как правило, такая нейронная сеть состоит из четырех слоев. В первом слое находятся нейроны, принимающие входные начальные параметры. На втором слое суммируются весовые вклады и вычисляется чистое значение при помощи вероятностного вектора. На третьем слое присутствует один нейрон для каждого заранее predetermined случая из обучающего массива данных, другими словами, образцовые примеры. Последний четвертый слой сравнивает результаты принадлежности объекта классу. Практические результаты показывают, что PNN намного быстрее обучается (требуется лишь один проход) и более точный, чем многослойный персептрон, а также нечувствительны к выбросам в выборках данных. Часто для улучшения работы PNN используют сторонние методы классификации. Благодаря скорости и точности, PNN часто используется на онлайн-площадках и приложениях, требующих анализа данных в реальном времени. Главный недостаток PNN – необходимо иметь много места для хранения информации.

Распознавание классическими методами. Авторы многих статей включают использование алгоритмов нечеткой логики в сочетании с векторами признаков, полученными путем вычисления текстурных признаков изображения, как классические методы идентификации аномалий и дефектов по изображениям [5]. Достаточно широкое распространение получили классификаторы, использующие принципы нечеткой логики. Данный подход подразумевает

определение степени принадлежности значений тем или иным классам при помощи специальных функций. Нечеткие классификаторы очень быстрые, но вместе с высокой скоростью страдает точность. Поэтому нечеткую логику лучше использовать в задачах, где точность заранее ограничена или не так важна, или в задачах реального времени.




Рис. 4. Схема устройства вероятностной нейронной сети  
 Fig. 4. Scheme of a probabilistic neural network

Обработка изображений при помощи нечеткой логики достаточно неопределенный процесс. Однако в совокупности с использованием других методов нечеткая логика демонстрирует хорошие результаты. Основная функция нечеткой логики при обработке изображений – устранить неточности и неоднозначности в предположениях при обработке изображения основным алгоритмом. Главным недостатком применения нечеткой логики является допустимая размерность, т.к. она не подходит для решения задач с большим количеством параметров.

Большинство авторов рекомендуют использовать матрицу GLCM для поиска особенностей текстур, наиболее точно отражающих статистический состав исследуемых изображений [6, 7].

На основе изучения вышеперечисленных методов классификации сделаны следующие выводы, результаты которых представлены в табл. 1. В качестве основного метода автоматизации диагностики в различных предметных областях, следует предпочесть два метода: нечеткую логику и матрицу смежности GLCM.

Для решения трудности выделения признаков в изображениях для целей классификации использовались разные способы для формирования набора признаков, которые разрешают однозначно идентифицировать изображение, т.е. отнести их к определенным классам. В частности, для решения проблемы выявления на изображениях объектов с отклонениями от нормы, с целью классификации этих отклонений возможно использовать текстурные особенности изображений. Наиболее широко используемыми особенностями для решения проблемы обнаружения дефектов и отклонений от нормы являются особенности, основанные на статистических признаках изображения (среднее значение, энергия, вариация, однородность, контраст, коэффициент корреляции, энтропия, дифференциальная дисперсия) по признакам, основанным на описании элементов структуры [8, 9].

При решении задач классификации изображений с большим количеством классов, например, 15 возможных вариантов отклонения от нормы, непосредственное использование ключевых признаков не приводит к положительным результатам, поскольку определенный тип отклонения определяется не спецификой ключевых признаков, а характеризуется функцией распределения значений ключевого признака. Также стоит обратить внимание, что функции распределения ключевых признаков разных отклонений от нормы у одного и того же объекта могут значительно пересекаться.

Если сравнивать изображения объектов, имеющих какие-либо отклонения от нормы и без отклонений, проще всего сделать это с помощью статистических методов и методов

сравнения текстур. Используя статистические методы, гистограмму дефектного объекта сравнивают с гистограммой объекта без дефектов и отклонений.

Сопоставляются центральные моменты гистограмм: математическое ожидание, дисперсию, величину скошенности и эксцесс. Кроме того, в качестве меры различия гистограмм предложены несколько метрик: метрика Евклида ( $L2$ ):

$$L2 = \left\{ \sum_{i=1}^N [f(x_i)\Delta x - g(x_i)\Delta x]^2 \right\}^{1/2} .$$

Однако однозначно определить характер отклонения или дефекта по описанным показателям невозможно, поскольку количество возможных типов отклонений у разных объектов достаточно велико.

Распространенным подходом к решению этой проблемы является сравнение параметров текстуры изображения, полученных на основе матриц смежности (матрица GLCM для изображений в оттенках серого и матрица ICICM для цветных изображений). В этом случае рассматриваемым объектом является не матрица изображения, а матрица смежности  $R, G, B, RG, RB, GB$ , на основе которой рассчитываются основные параметры текстуры: контраст, корреляция, энергия, энтропия, однородность:

- 1) contrast;
- 2) correlation;
- 3) energy;
- 4) homogeneity.

Однако использование этих параметров непосредственно для диагностики типов отклонения от нормы не дает точных результатов, поскольку «эталонное» описание для каждого типа смещения – это не набор значений для параметров текстуры, а набор функций, распределения данных параметров. Отличительной особенностью функций распределения параметров текстур обрабатываемых изображений: контраст, корреляция, энтропия, однородность являются сильные перекрытия, тем самым исключая возможность формирования порогов по критериям Неймана-Пирсона и не позволяет однозначно распознать вид конкретного отклонения от нормы.

Для преодоления данного недостатка рекомендуется создавать эталонные описания в виде границ доверительного интервала функции распределения параметров текстуры для всех анализируемых изображений объектов с какими-либо отклонениями от нормы: контрастности, корреляции, энергии, однородности для компонентов  $R, G, B, RG, RB, GB$  изображений обучающей выборки, определять соответствующие взаимосвязи между значениями параметров текстуры нормализованного анализируемого изображения и доверительным интервалом, эталонного описания и принятия решения о принадлежности анализируемого изображения к одному из возможных видов путем мажоритарного голосования и бинаризации результатов.

## Результаты

**Описание предлагаемого метода.** Предлагаемый метод включает формирование параметров текстур на основе показателей контраста, корреляции, энергии, однородности и использование нечеткой логики для формирования результатов распознавания. Целесообразность её использования в проблеме диагностики различных дефектов и отклонений от норм изображения рассмотрена в [9]. Особенностью предлагаемого решения этой проблемы является то, что оно включает в себя определение того, принадлежит ли каждое из 6-ти множеств  $R, G, B, RG, RB, GB$  эталонному описанию, бинаризацию результата и, наконец, принятие решения о том, является ли изображение принадлежащим к одному из возможных типов путем мажоритарного голосования. На рис. 5 представлена предлагаемая структура системы диагностики отклонений от нормы на примере болезней растений по изображениям их листьев.

Предлагаемая методика диагностики состоит из двух этапов. На первом этапе рассчитываются параметры контрастности, корреляции, энергии, однородности и сравниваются с эталонным описанием в виде диапазонов значений параметров для всех отклонений и бинаризуются результаты диагностики (бинаризованные значения являются единицей, если зна-

чение параметров входит в диапазон эталонного описания при данном отклонении, или 0, если не включено). При анализе матрицы смежности, в частности, красной составляющей изображения и расчете модельных значений параметров контрастности, корреляции, энергии, однородности, как сумма центров распределения и случайного отклонения, диапазон значений параметров эталонного описания  $D$  (доверительный интервал для заданного уровня достоверности), принимается фиксированным, определяя величину, исходя из количества параметров.

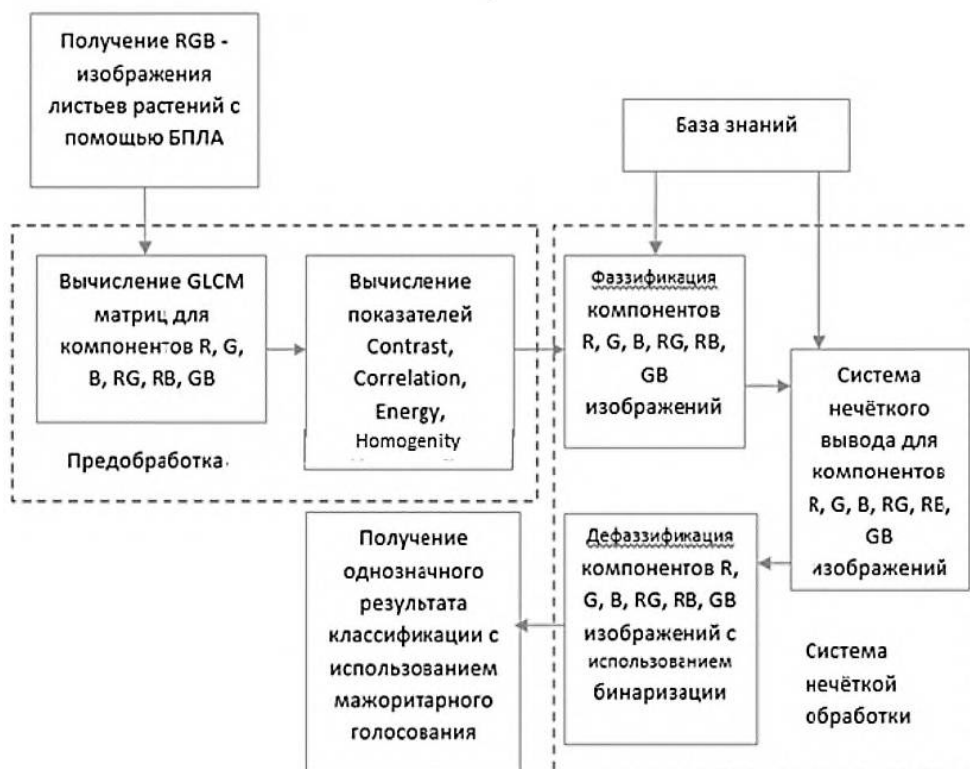


Рис. 5. Структура системы диагностики заболеваний растений по изображениям листьев  
 Fig. 5. The structure of the system for diagnosing plant diseases based on leaf images

В случае, когда доверительный интервал, описанный в эталоне, больше необходимого значения, требуется получить среднее значение параметров контраста, корреляции, энергии и однородности нескольких ( $M$ ) анализируемых изображений и выбрать количество усредняемых значений параметров из условия, что среднее значение параметров контрастности, корреляции, энергии и однородности не превышает  $D$ . Если доверительный интервал значеный какого-то параметра без учета его усреднения равен  $D1$  и  $D1 > D$ , то при условии, что закон распределения значения параметра близок к нормальному, необходимое количество усреднений  $M$  вычисляется на основе выражения для доверительного интервала математического ожидания:

$$M = \frac{D1^2}{D^2}.$$

Использование одного ключевого параметра: контрастности, корреляции, энергии или однородности не позволяет однозначно идентифицировать вид отклонения. Лучших результатов можно добиться путем мажоритарного голосования.

На втором этапе предлагается суммировать результаты бинаризации компонентов  $R$ ,  $G$ ,  $B$ ,  $RG$ ,  $RB$  и  $GB$ , полученные на первом этапе, а затем вычислять окончательный результат анализа изображения мажоритарным голосованием.

Данными для алгоритма диагностики служат эталонные описания изображений при всех возможных отклонениях от нормы: математические ожидания показателей  $CN$ ,  $EN$ ,  $CR$ ,  $HM$  и доверительные интервалы функций распределения  $DCN$ ,  $DEN$ ,  $DCR$ ,  $DHM$  значений этих параметров.

Описание алгоритма. Исходными данными для диагностического алгоритма являются эталонные описания изображений листьев всех болезней: математическое ожидание показателей  $CN0$ ,  $EN0$ ,  $CR0$ ,  $HM0$  и значения доверительных интервалов  $DCN$ ,  $DEN$ ,  $DCR$ ,  $DHM$  для функций распределения значений этих параметров.

Последовательность действий.

1. Рассчитываются значения показателей контраста, корреляции, энергии, однородности для всех компонентов изображения:  $R$ ,  $G$ ,  $B$ ,  $RG$ ,  $RB$ ,  $GB$  (номер компонента  $j = 1 \dots 6$ ) и расчёт показателей сравнения исходного изображения с описаниями, взятыми за эталон, для всех возможных компонентов и всех отклонений:

$$KCN(i, j) = \frac{|CN(i, j) - CN0(i, j)|}{DCN(i, j)};$$

$$KEN(i, j) = \frac{|EN(i, j) - EN0(i, j)|}{DEN(i, j)};$$

$$KCR(i, j) = \frac{|CR(i, j) - CR0(i, j)|}{DCR(i, j)};$$

$$KHM(i, j) = \frac{|HM(i, j) - HM0(i, j)|}{DHM(i, j)}.$$

2. Первичная бинаризация показателей:

$$KCNB(i, j) = 1, \text{ если } KCN(i, j) \leq 1 \text{ и } 0, \text{ если } KCN > 1;$$

$$KENB(i, j) = 1, \text{ если } KEN(i, j) \leq 1 \text{ и } 0, \text{ если } KEN > 1;$$

$$KCRB(i, j) = 1, \text{ если } KCR(i, j) \leq 1 \text{ и } 0, \text{ если } KCR > 1;$$

$$KHMB(i, j) = 1, \text{ если } KHM(i, j) \leq 1 \text{ и } 0, \text{ если } KHM > 1.$$

3. Первичное мажоритарное голосование и вторичная бинаризация результатов голосования:

$$KB(i, j) = KCNB(i, j) + KENB(i, j) + KCRB(i, j) + KHMB(i, j);$$

$$KB1(i, j) = \text{round}\left(\frac{KB(i, j) - 0,1}{4}\right).$$

4. Окончательное мажоритарное голосование и бинаризация:

$$KBG(i) = \sum_{j=1}^6 KBB(i, j);$$

$$K(i) = \text{round}\left(\frac{(KBG(i) - 0,1)}{6}\right).$$

### Заключение

Для классификации текстурных изображений с большим количеством классов надежные результаты получаются путем расчета матрицы смежности (GLCM) и описания эталонных классов в виде пределов доверительного интервала для функций распределения текстурных параметров: контраста, корреляции, энергии, однородности, для компонентов изображения  $R$ ,  $G$ ,  $B$ ,  $RG$ ,  $RB$ ,  $GB$  выполнение операции фазсификации с формированием нечеткого вывода о принадлежности к определенному классу, выполнение дефазсификации с использованием бинаризации признаков и мажоритарного голосования.

Достоверность результатов классификации повышается, если для диагностики использовать среднее значение параметров контрастности, корреляции, энергии, однородности нескольких анализируемых изображений одного класса.

Предложенный подход к классификации текстурных изображений успешно применяется для диагностики различных отклонений, как эффективный и точный метод автоматизированной диагностики. Данный подход включен в системы контроля на основе компьютерного зрения в сельскохозяйственной деятельности, медицине, промышленности для повышения производительности и эффективности.



## СПИСОК ИСТОЧНИКОВ

1. Рыбаков А.В., Ходарова З.М. Перспективы использования мобильных роботов с системами технического зрения в сельском хозяйстве // Сборник научных трудов VII Международной научной - практической конференции «Симметрии: теоретический и методический аспекты». – 2018. – С. 39 – 46.
2. Рыбаков А. В., Лихтер А. М., Погожева А. Б., Михайлова А. В., Дусалиев А. Б. Проектирование робототехнических манипуляторов с системой компьютерного зрения для сбора томатов // Прикаспийский журнал: управление и высокие технологии. – 2020. – №3. – Стр. 135-147
3. Diptesh Majumdar, Dipak Kumar Kole, Aruna Chakraborty, and Dwijesh Dutta Majumder. «An Integrated Digital Image Analysis System for Detection, Recognition and Diagnosis of Disease in Wheat Leaves.» In Proceedings of the Third International Symposium on Women in Computing and Informatics, ACM, 2015, pp. 400- 405.
4. Jayme Garcia Arnal Barbedo. Digital image processing techniques for detecting, quantifying and classifying plant diseases / Barbedo SpringerPlus 2013, 2:660.
5. Jyotismita Chaki, Ranjan Parekh. Designing an Automated System for Plant Leaf Recognition / IJAET, Vol.2, Issue. 1, 2012, pp: 149-158.
6. Liu T., Wu W., Chen W., Sun C., Zhu X., Guo W., Automated image-processing for counting seedlings in a wheat field. *Precis. Agric.* 2016, 17, 392–406.
7. Gagarina L.G., Garashchenko A.V., Ye K.Z., Dorogova E., Kochneva, M. Development of an Approach to Automatic Test Generation Based on the Graph Model of a Cache Hierarchy // Proceedings of the 2020 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus 2020, pp. 1940-1944.
8. Histograms/ NASA Langley Research Center, Hampton, VA. <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/20080015431.pdf>
9. Битоков С.И., Максимушкина А.В., Смирнова В.В. Сравнение гистограмм в физических исследованиях // Известия вузов. Ядерная энергетика. – 2016. – № 1. – С. 108–111.

### Информация об авторах:

**Андрей Владимирович Чирков**  
аспирант, специалист по учебно-методической работе каф. Института СПИНТех Национального исследовательского университета «МИЭТ»; AuthorID-РИНЦ: 1068753.

**Лариса Геннадьевна Гагарина**  
доктор технических наук, директор каф. Института СПИНТех Национального исследовательского университета «МИЭТ»; AuthorID-РИНЦ: 101760.

**Николай Сергеевич Миронов**  
аспирант каф. Института СПИНТех Национального исследовательского университета «МИЭТ».

**Роман Викторович Липовый**  
аспирант каф. Института СПИНТех Национального исследовательского университета «МИЭТ».

## References:

1. Rybakov AV, Khodarova ZM. Prospects for Using Mobile Robots with Vision Systems in Agriculture. In: Proceedings of the 7th International Scientific and Practical Conference: Symmetries: Theoretical and Methodological Aspects; 2018. p. 39-46.
2. Rybakov A.V., Likhter A.M., Pogozheva A.B., Mikhailova A.V., Dusaliev A.B. Design of Robotic Manipulators with a Computer Vision System for Picking Tomatoes. *Caspian Journal: Mangement and High Technologies.* 2020;3:135-147.
3. Majumdar D, Kumar Kole D, Chakraborty A, Majumder DD. An Integrated Digital Image Analysis System for Detection, Recognition and Diagnosis of Disease in Wheat Leaves. In: Proceedings of the 3rd International Symposium on Women in Computing and Informatics. New York, NY: ACM: 2015. p. 400-405.
4. Arnal Barbedo J.G. Digital Image Processing Techniques for Detecting, Quantifying and Classifying Plant Diseases. *SpringerPlus.* 2013;2:660.
5. Chaki J., Parekh R. Designing an Automated System for Plant Leaf Recognition. *IJAET.* 2012;2(1):149-158.
6. Liu T., Wu W., Chen W., Sun C., Zhu X., Guo W. Automated Image-Processing for Counting Seedlings in a Wheat Field. *Precis. Agric.* 2016;17:392-406.
7. Gagarina LG, Garashchenko AV, Ye KZ, Dorogova E, Kochneva M. Development of an Approach to Automatic Test Generation Based on the Graph Model of a Cache Hierarchy. In: Proceedings of the 2020 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering; St-Petersburg: ElConRus: 2020. p. 1940-1944.
8. Histograms. NASA Langley Research Centre [Internet]. Hampton (VA); 2005. Available from: <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/20080015431.pdf>
9. Bityukov S.I., Maksimushkina A.V., Smirnova V.V. Comparison of Histograms in Physical Research. *Izvestiya vuzov. Yadernaya Energetika.* 2016;1:108-111.

### Information about authors:

**Andrey Vladimirovich Chirkov**  
post-graduate student, specialist on educational and methodical work of the Department of System and Software Engineering and Information Technology Institute of National Research University of Electronic Technology «MIET»; Author iD-RSCI: 1068753.

**Larisa Gennadievna Gagarina**  
Doctor of Technical Sciences, Director of the Department of System and Software Engineering and Information Technology Institute of National Research University of Electronic Technology «MIET»; Author iD-RSCI: 101760.

**Nikolai Sergeevich Mironov**  
post-graduate student of the Department of System and Software Engineering and Information Technology Institute of National Research University of Electronic Technology «MIET».

**Roman Viktorovich Lipov**  
post-graduate student of the Department of System and Software Engineering and Information Technology Institute of National Research University of Electronic Technology «MIET».

**Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.**

**Contribution of the authors: the authors contributed equally to this article.**

**Авторы заявляют об отсутствии конфликта интересов.**

**The authors declare no conflicts of interests.**

**Статья поступила в редакцию 20.07.2022; одобрена после рецензирования 29.07.2022; принята к публикации 01.09.2022.**

**The article was submitted 20.07.2022; approved after reviewing 29.07.2022; accepted for publication 01.09.2022.**

**Рецензент – Малаханов А.А., кандидат технических наук, доцент, Брянский государственный технический университет.**

**Reviewer – Malakhanov A.A., Candidate of Technical Sciences, Associate Professor, Bryansk State Technical University.**