

СИСТЕМА КЛАССИФИКАЦИИ ТЕКСТУРНЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ НЕЧЕТКОЙ ЛОГИКИ

CLASSIFICATION SYSTEM OF TEXTURED IMAGES BASED ON FUZY LOGIC

V. Tutygin
Al Windi Basim Khalid Mohammed Ali

Summary. New method, including the calculation of the adjacency matrix (GLCM) and reference descriptions of classes in the form of boundaries of confidence intervals of texture distribution parameters: Contrast, Correlation, Energy, Homogeneity, for R, G, B, RG, RB, GB image components, performing fuzzification operation with the formation of fuzzy conclusions about belonging to a particular class, performing defuzzification using the binarization of features and majority voting.

Keywords: GLCM-matrix, fuzzy set of pictures, fuzzy logic, binarization of key features, majority voting.

Тутыгин Владимир Семёнович

*К.т.н., доцент, Санкт-Петербургский
политехнический университет, Санкт-Петербург*

Аль Винди Басим Халид Мохаммед Али

*Аспирант, Санкт-Петербургский политехнический
университет, Санкт-Петербург
vs4141@mail.ru*

Аннотация. Новый способ, включающий вычисление матрицы смежности (GLCM) и эталонных описаний классов в виде границ доверительных интервалов функций распределения параметров текстур: Contrast, Correlation, Energy, Homogeneity, для компонентов изображений R, G, B, RG, RB, GB, выполнение операции фаззификации с формированием нечётких выводов о принадлежности к определённому классу, выполнение дефаззификации с использованием бинаризации признаков и мажоритарного голосования.

Ключевые слова: GLCM — матрица, нечеткое множество параметров изображений, нечеткая логика, бинаризация ключевых признаков, мажоритарное голосование.

Введение

Для решения задачи выделения особенностей на изображениях с целью их классификации применяются различные методы формирования набора признаков, позволяющих однозначно идентифицировать изображения, т.е. относить их к определённому классу. В частности, для решения задачи выделения особенностей изображений листьев растений с целью классификации вида заболевания растений могут использоваться текстурные признаки изображений листьев.

Наибольшее применение при решении задач распознавания болезней растений по изображениям листьев нашли признаки текстуры, использующие матрицы смежности (матрицы GLCM для полутоновых изображений и ICICM — для цветных изображений), признаки, основанные на измерении пространственных частот, признаки, использующие статистические характеристики изображений (среднее, энергия, вариация, однородность, контраст, коэффициент корреляции, энтропия, дифференциальная дисперсия), признаки, основанные на описании структурных элементов [1–4].

В том случае, когда решается задача классификации изображений при большом количестве классов, например, 15 возможных заболеваний растений, непосредственное использование ключевых признаков не даёт

положительного результата, т.к. любой конкретный вид заболевания характеризуется не конкретным значением ключевого признака, а функцией распределения значений ключевого признака. Кроме того, функции распределения ключевых признаков для разных болезней могут иметь существенные пересечения.

Выбор системы ключевых признаков. Наиболее просто использовать статистический метод и метод сравнения текстур, если сравнению подлежат изображения листа здорового растения и больного растения. При использовании статистического метода можно производить сравнение гистограмм больных растений с гистограммой здорового растения.

Сравнивать можно центральные моменты гистограмм: математическое ожидание, дисперсию, величину скошенности (3-й момент) и эксцесс (4-й момент). Кроме того, в качестве меры различия гистограмм предложены несколько метрик [3, 4]: метрика Евклида (L2):

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

см. формулу (2). Метрика Джеффриса-Матусита (JM):
см. формулу (3), метрика Колмогорова — Смирнова (KS)

см. формулу (4) метрика Купера (Kuiper)

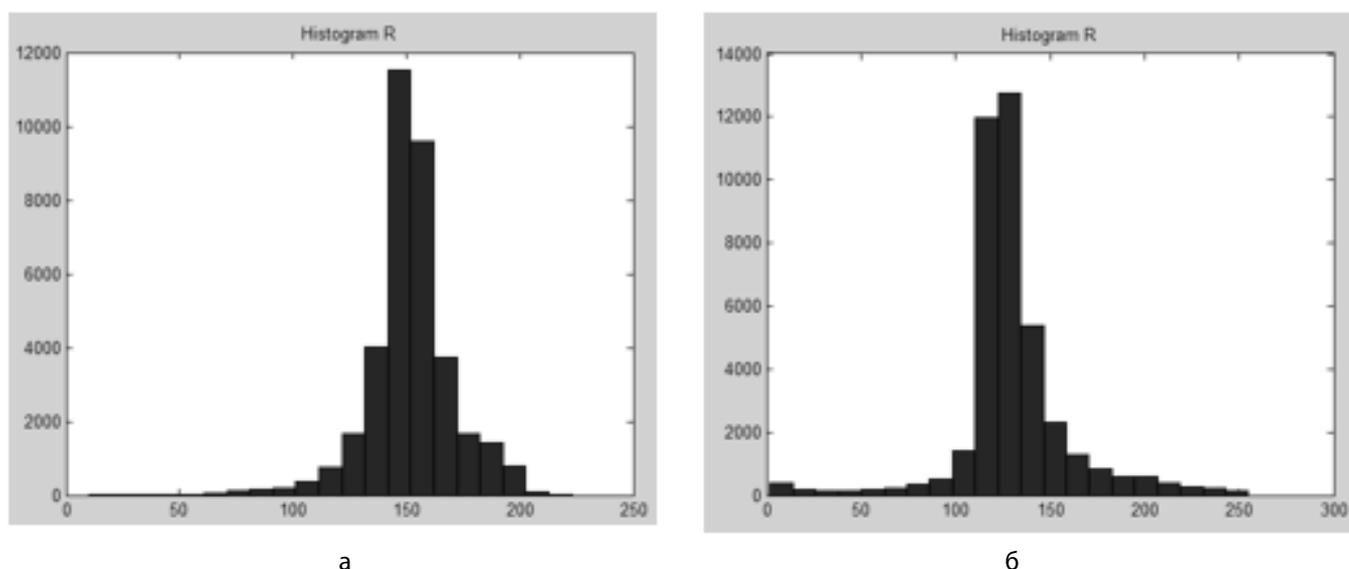


Рис. 1. Гистограммы яркостей изображения здорового (А) и больного (Б) эвкалиптов

Использование матрицы смежностей (**GLCM-матрицы**). Однако однозначно определить вид заболевания растений (в частности, пшеницы или сои) на основе описанных метрик невозможно, т.к. количество видов заболеваний у сельскохозяйственных культур достаточно велико (например, количество основных заболеваний пшеницы или сои — более 15 [5,6]), а различие гистограмм изображений с разными видами заболеваний незначительно. Пример изображений листьев пшеницы при различных заболеваниях приведён на рис. 2.

Известный подход к решению этой задачи основан на сравнении параметров текстур изображений, полученных на основе матрицы смежностей (матрицы GLCM для полутоновых изображений и ICIM — для цветных

изображений [7, 8]). В этом случае объектом анализа является не матрица изображения, а матрицы смежности R, G, B, RG, RB, GB, на основе которых вычисляются основные параметры текстуры: Contrast, Correlation, Energy, Entropy, Homogeneity:

- 1) contrast:
- 2) correlation:
- 3) energy:
- 4) homogeneity:

где u, v — координаты матрицы смежности, G — количество уровней серого, μ_u, μ_v, σ_u и σ_v — средние значения и стандартные отклонения u -й строки и v -го столбца матрицы совпадения соответственно. Приведённые выше определения гарантируют, что все функции имеют диапазон $[0, 1]$.

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

$$KS = \text{Max}_i \left[\sum_1^i |f(x_i) - g(x_i)| \Delta x \right] \quad \text{where } i = 1, 2, \dots, N \quad (3)$$

$$Kp = \text{Max}_i \left[\sum_1^i \{f(x_i) - g(x_i)\} \right] + \text{Max}_i \left[\sum_1^i \{g(x_i) - f(x_i)\} \right], \quad \text{where } i = 1, 2, \dots, N \quad (4)$$

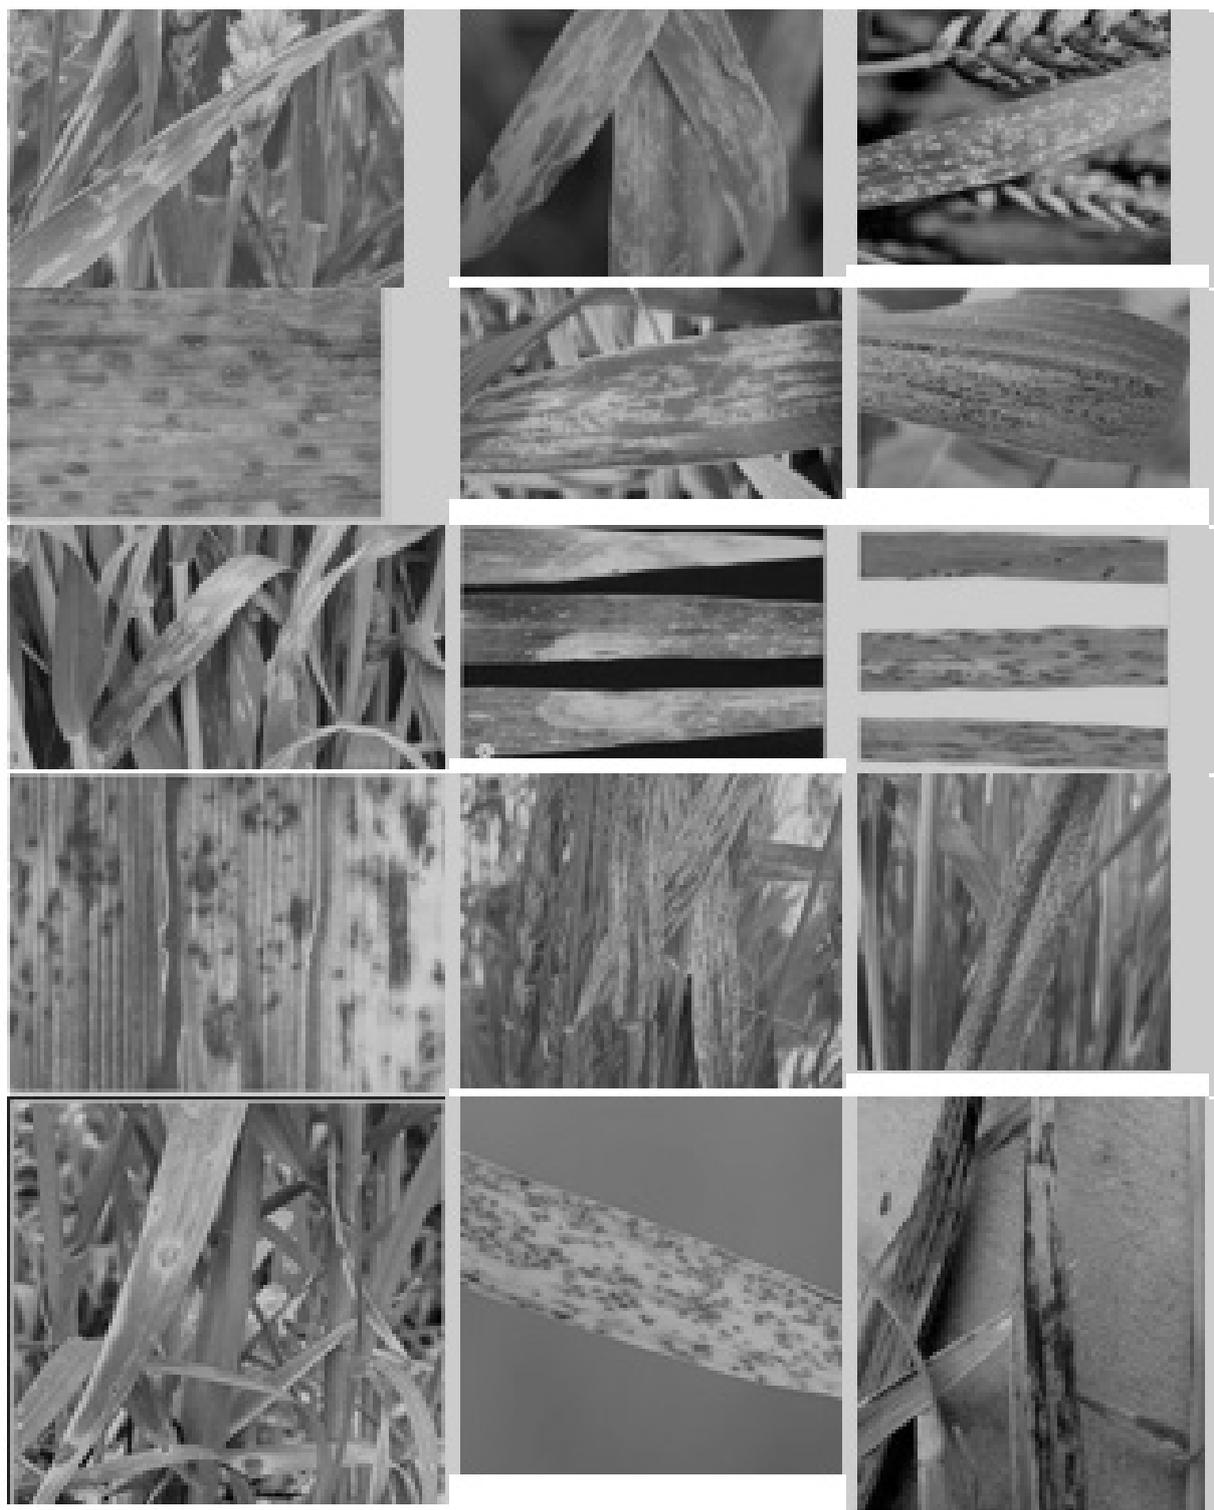


Рис. 2. Фотоизображения листьев пшеницы при различных заболеваниях. 1- Септориоз (*Septoria*), 2 — пиренофороз (*Pyrenophora tritici-repentis*), 3 — Мучнистая роса (*Erysiphe graminis*), 4 — Ржавчина бурая (*Puccinia recondita*), 5, 6 — Ржавчина желтая (*Puccinia striiformis*), 7 — Септориоз листьев (*Septoria tritici*), 8 — Снежная плесень (*Fusarium nivale*), 9 — Гельминтоспориоз (*Helminthosporium sativum*), 10 — Корневые гнили, 11 — Полосатая мозаика (Wheat stripe mosaic virus), 12 — Бурая (листовая) ржавчина (Грибные болезни (*Puccinia triticina*)), — 13 — Гельминтоспориоз (*Pyrenophora tritici-repentis*), 14 — Линейная (стеблевая) ржавчина (*Puccinia graminis*), 15 — Пыльная головня (*Ustilago tritica*)

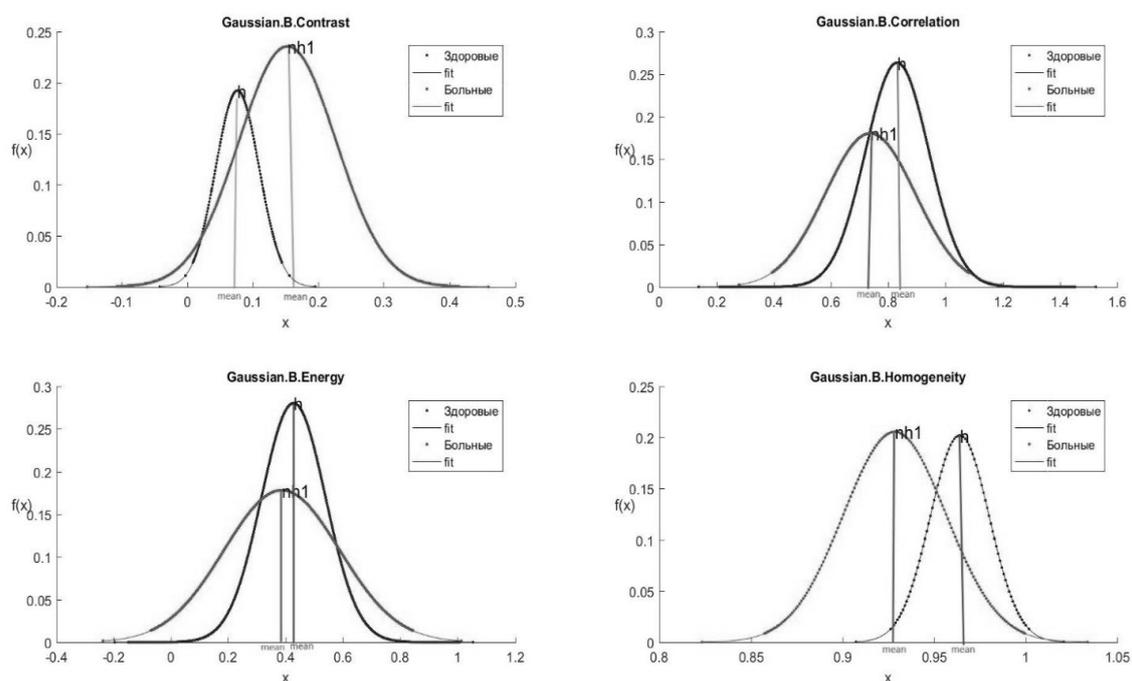


Рис. 3. Пример функций распределения параметров текстур для В-компоненты нормализованных изображений листьев эвкалиптов.

Однако непосредственное использование этих параметров для целей диагностики вида заболевания также не приводит к однозначно правильному результату, т.к. «эталонным» описанием каждого вида заболевания является не набор фиксированных значений параметров текстур, а набор функций распределения этих параметров (см. рис. 3).

Характерная особенность функций распределения параметров текстур фотоизображений листьев: Contrast, Correlation, Energy, Entropy, Homogeneity — значительные перекрытия (см. рис. 3), что исключает возможность формирования порогов распознавания по критериям идеального наблюдателя или Неймана — Пирсона и однозначной идентификации вида заболевания.

Использование нечёткой логики

Для преодоления этого недостатка нами предлагается создание эталонных описаний нормализованных изображений для всех анализируемых болезней в виде границ доверительных интервалов функций распределения параметров текстур: Contrast, Correlation, Energy, Homogeneity, — для компонентов R, G, B, RG, RB, GB изображений обучающей выборки, определение соответствия значений параметров текстур нормализованного

анализируемого изображения доверительным интервалам эталонного описания и принятие окончательного решения о принадлежности изображения к одному из возможных видов путём бинаризации результатов сравнения и мажоритарного голосования.

Предлагаемый нами подход заключается в формировании параметров текстур на основе показателей Contrast, Correlation, Energy, Homogeneity [7], а для формирования результатов распознавания применение нечёткой логики [8]. Целесообразность её использования при решении задачи диагностики заболеваний растений по изображениям листьев рассмотрена в [9]. Отличительной особенностью предлагаемого нами решения этой задачи состоит в том, что оно предполагает определение принадлежности к эталонным описаниям каждого из 6 наборов R, G, B, RG, RB, GB, бинаризацию результатов и принятие окончательного решения о принадлежности изображения к одному из возможных видов путём мажоритарного голосования.

На рис. 3 приведена предлагаемая структура системы диагностики заболеваний растений по изображениям листьев.

Предлагаемая методика диагностики включает два этапа.

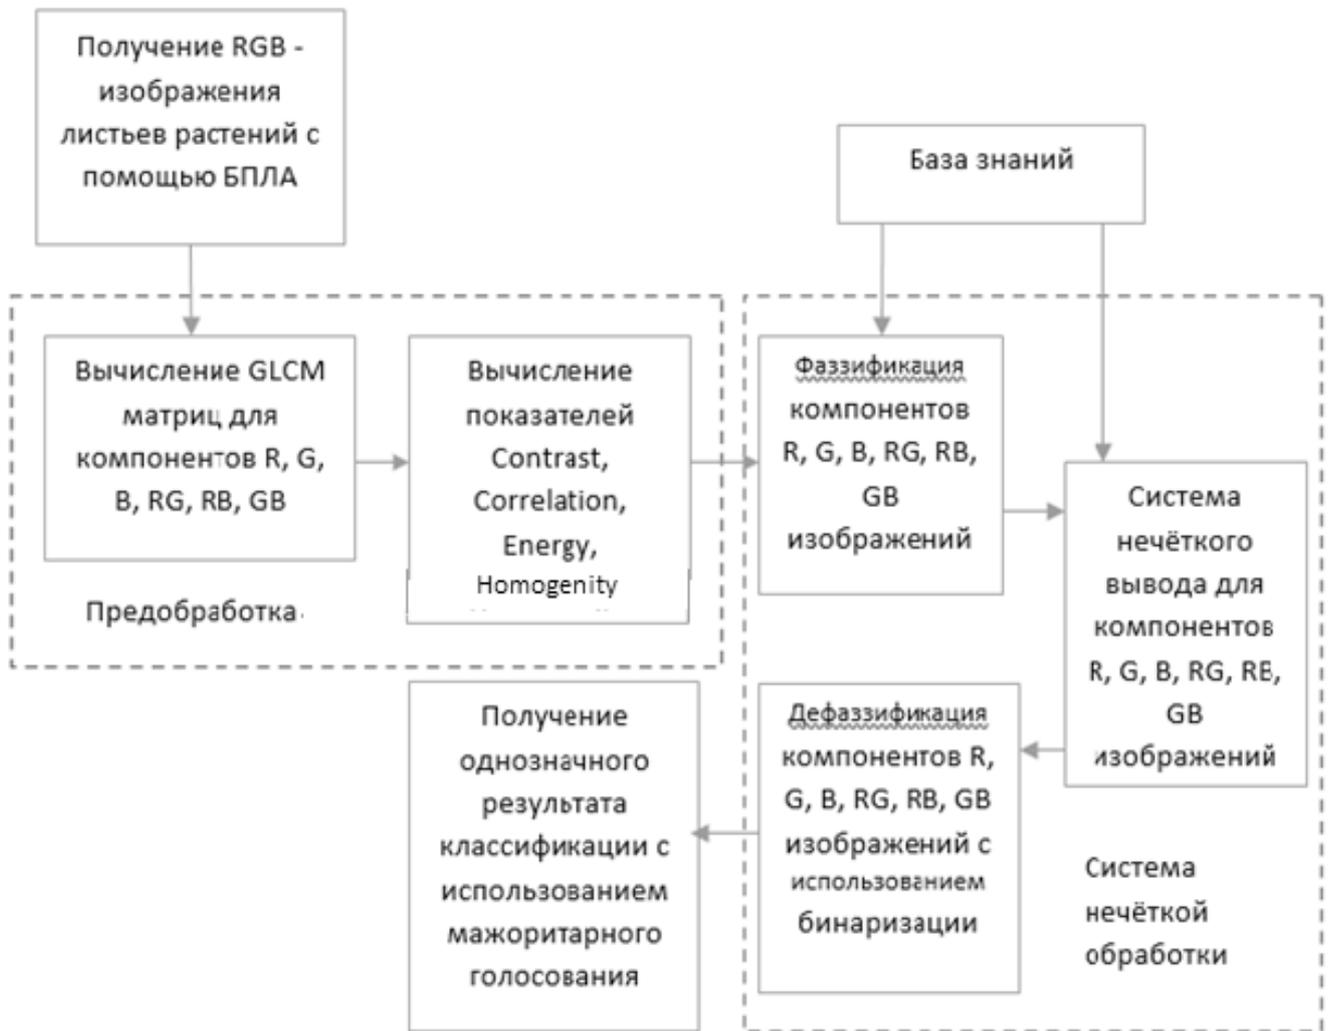


Рис. 3. Структура системы диагностики заболеваний растений по изображениям листьев.

На первом этапе производится вычисление параметров Contrast, Correlation, Energy, Homogeneity и сравнение с эталонными описаниями, в виде диапазона значений параметров при всех заболеваниях и бинаризацией результатов диагностики (значение бинаризованного результата сравнения равно 1, если значение параметров входит в диапазон эталонного описания при данном заболевании, и 0 — если не входит). В приведённой таблице 1 приведены результаты моделирования процесса диагностики для случая, когда анализируется матрица смежности для красной составляющей изображения, а модельные значения параметров Contrast, Correlation, Energy, Homogeneity вычислены как сумма центра распределения и случайного отклонения для болезни 3. Диапазон значений параметров эталонного описания D (доверительный интервал для заданного уровня доверительной вероятности) можно взять фиксированным для всех 24 параметров и равным ± 0.08 как показали результаты моделирования, т.е. $D=0.16$.

В том случае, если доверительные интервалы эталонных описаний больше этого значения, необходимо получать усреднённые значения параметров Contrast, Correlation, Energy, Homogeneity для нескольких (M) анализируемых изображений листьев (это возможно, т.к. в области поражения болезнью всегда находится несколько растений), а количество усредняемых значений параметров выбирать из условия, чтобы доверительный интервал с учётом произведённого усреднения значений параметров Contrast, Correlation, Energy, Homogeneity был не более D . Если доверительный интервал значений какого-либо параметра без учёта усреднения равен $D1$, $D1 > D$, то в предположении, что закон распределения значений этого параметра близок к нормальному, необходимое количество усреднений M может быть вычислено на основе известного выражения для доверительного интервала математического ожидания как

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

Таблица 1.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Параметр распознавания GLCM															
Contrast	0	0	1	0	1	0	0	0	0	0	1	0	0	0	0
Correlation	1	1	1	0	0	0	1	1	1	0	0	1	1	0	1
Energy	0	0	1	0	1	0	0	0	0	0	1	0	1	1	1
Homogeneity	1	0	1	0	1	1	1	0	1	0	1	0	1	1	1
Результат диагностики после мажоритарного голосования	2	1	4	0	3	1	2	1	2	0	3	1	3	2	3
Результат бинаризации			1								1		1		1

Таблица 2

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Параметр распознавания GLCM															
R	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0
G	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0
RG	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0
RB	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
GB	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1
Результат диагностики после мажоритарного голосования	0	0	5	0	0	0	1	0	0	1	0	0	1	0	1
Результат бинаризации	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0

По результатам проведённых измерений значений параметров для набора из 160 изображений листьев эвкалипта (80 — здоровых и 80 — больных) и 300 изображений листьев пшеницы (100 здоровых, 100 больных септориозом и 100 — бурой ржавчиной) максимальная величина D_1 в расчёте на доверительную вероятность, равную 0.95 составила +/-0.4, т.е. $D_1=0.8$. Отсюда следует, что достаточное количество усреднений равно 25.

Из приведённой таблицы видно, что использование какого-либо одного ключевого параметра: Contrast, Correlation, Energy или Homogeneity не позволяет однозначно идентифицировать вид заболевания. Более хороший результат можно получить, используя мажоритарное голосование.

На этом этапе однозначный результат распознавания ещё не получается (см. табл. 1).

На втором этапе мы предлагаем суммировать результаты бинаризации, полученные на первом этапе для компонентов R, G, B, RG, RB, GB, а затем вычислять окон-

чательный результат диагностики путём мажоритарного голосования.

Результаты второго этапа диагностики, полученные путём моделирования при заданном уровне доверительной вероятности 0.95 приведённые в табл. 2 в качестве примера, показывают, что результаты бинаризации определяют вид заболевания с заданным уровнем доверительной вероятности.

Исходными данными для алгоритма диагностики являются эталонные описания изображений листьев при всех заболеваниях: математические ожидания показателей CN, EN, CR, HM и значения доверительных интервалов DCN, DEN, DCR, DHM для функций распределения значений этих параметров. При проведении модельного эксперимента математические ожидания показателей CN, EN, CR, HM были взяты равными значениям параметров, полученных при обработке изображений листьев пшеницы для всех 15 болезней, а доверительные интервалы DCN, DEN, DCR, DHM были взяты равными 0.16. Статистические оценки результатов диа-

гностики предложенным способом проводились для каждой из 15 болезней. В результате 15000 проведённых модельных экспериментов (по 1000 экспериментов для каждой из 15 болезней) правильная диагностика составила 93.6–96%.

Описание алгоритма. Исходными данными для алгоритма диагностики являются эталонные описания изображений листьев при всех заболеваниях: математические ожидания показателей CN0, EN0, CR0, HM0 и значения доверительных интервалов DCN, DEN, DCR, DHM для функций распределения значений этих параметров.

Последовательность действий.

1. Вычисление значений показателей Contrast, Correlation, Energy, Homogeneity для всех компонентов изображения: R, G, B, RG, RB, GB (номер компонента $j=1.6$) и вычисление показателей сравнения исходного изображения листа с эталонными описаниями для всех компонентов и всех болезней: $KCN(i, j)$, $KEN(i, j)$, $KCR(i, j)$, $KHM(i, j)$, ($j=1.6, i=1.15$):

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

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

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

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

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

1. Для классификации текстурных изображений при значительном количестве классов надёжные результаты даёт вычисление матрицы смежности (GLCM) и эталонных описаний классов в виде границ доверительных интервалов функций распределения параметров текстур: Contrast, Correlation, Energy, Homogeneity, для компонентов изображений R, G, B, RG, RB, GB, выполнение операции фаззификации с формированием нечётких выводов о принадлежности к определённому классу, выполнение дефаззификации с использованием бинаризации признаков и мажоритарного голосования.

2. Достоверность результатов классификации может быть повышена, если использовать для диагностики усреднённые значения параметров Contrast, Correlation, Energy, Homogeneity для нескольких анализируемых изображений, принадлежащих к одному классу.

3. Предложенный подход к классификации текстурных изображений может быть успешно применён для диагностики заболеваний сельскохозяйственных культур по изображениям листьев.

ЛИТЕРАТУРА

1. Денисюк В. С. Алгоритмы выделения особенностей на изображениях с целью классификации заболеваний растений. https://www.iis.nsk.su/files/articles/sbor_kas_16_denisjuk.pdf
2. Kuan-Man Xu. Using the Bootstrap Method for a Statistical Significance Test of Differences Between Summary. .
3. Histograms/ NASA Langley Research Center, Hampton, VA. <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/20080015431.pdf>
4. S.I.Bityukov, A. V. Maksimushkina, V. V. Smirnova Comparison of histograms in physical research /Nuclear Energy and technology 2 (2016), 108–113.
5. Francesco Bianconi, Richard Harvey, Paul Southam, Antonio Fernandez. Theoretical and experimental comparison of different approaches for colour texture classification / <https://pdfs.semanticscholar.org/31a0/cf98ca459ab6e4676ac45700cc2485358347.pdf>
6. М.Койшибаев. Болезни пшеницы. Продовольственная и сельскохозяйственная организация ООН (ФАО), Анкара, 2018. 365с.

7. Йорданка Станчева. Атлас болезней сельскохозяйственных культур. Т. 3., Болезни полевых культур. София — Москва, Изд. ПЕНСОФТ, 2003г
8. Jayme Garcia Arnal Barbedo Digital image processing techniques for detecting, quantifying and classifying plant diseases / Barbedo SpringerPlus 2013, 2:660 / <http://www.springerplus.com/content/2/1/660/>
9. С.Д.Штовба. Введение в теорию нечетких множеств и нечеткую логику/ <http://matlab.exponenta.ru/fuzzylogic/index.php>
10. Аунг Ч.Х., Тант З. П., Федоров А. Р., Федоров П. А. Разработка алгоритмов обработки изображений интеллектуальными мобильными роботами на основе нечёткой логики и нейронных сетей // Современные проблемы науки и образования. — 2014. — № 6.

© Тутыгин Владимир Семёнович, Аль Винди Басим Халид Мохаммед Али (vs4141@mail.ru).
Журнал «Современная наука: актуальные проблемы теории и практики»



Санкт-Петербургский политехнический университет