

НОВЫЙ МЕТОД ДИАГНОСТИКИ БОЛЕЗНЕЙ РАСТЕНИЙ НА ОСНОВЕ ЦИФРОВОГО ОПИСАНИЯ ИЗОБРАЖЕНИЙ ЛИСТЬЕВ И НЕЙРОННОЙ СЕТИ ПРЯМОГО РАСПРОСТРАНЕНИЯ

A NEW METHOD FOR DIAGNOSTICS OF PLANT DISEASES BASED ON DIGITAL DESCRIPTION OF LEAF IMAGES AND FORWARD PROPAGATION NEURAL

V. Tutygin
O. Prokofiev

Summary. A new approach to building a software system for diagnosing plant diseases from leaf images based on digital descriptions of leaf images in the form of sets of Haralik parameters in the form of png images for each of the color components of leaf images and a feed-forward neural network. The task of preprocessing is to prepare a data set (leaf images) by normalizing the sizes and generating digital descriptions as input to the neural network. This is achieved by using GLCM and calculating a set of 4 Haralik parameters that reflect the features of the image texture and at the same time have a much lower dimension. In this regard, convolution operations in the structure of the neural network are excluded, which significantly reduces the time spent on training the neural network and diagnostics. Real images of leaves for all plant diseases are used to train the neural network. The large amount of initial data required for training is created using randomization.

Keywords: Photo image normalization, GLCM — matrix, Haralik parameters, digital descriptions of leaf images, feed-forward neural network.

Тутыгин Владимир Семёнович

К.т.н., доцент

Санкт-Петербургский политехнический
университет
Санкт-Петербург

Прокофьев Олег Валерьевич

Старший преподаватель

Санкт-Петербургский политехнический
университет
Санкт-Петербург
vs4141@mail.ru

Аннотация. Новый подход к построению программной системы диагностики заболеваний растений по изображениям листьев на основе цифровых описаний изображений листьев в виде наборов параметров Харалика в виде изображений в формате png для каждой из цветовых составляющих изображений листьев и нейронной сети прямого распространения. Задача предварительной обработки заключается в подготовке набора данных (изображений листьев) путем нормализации размеров и создания цифровых описаний в качестве входных данных нейронной сети. Это достигается с помощью GLCM и расчета 4-х параметров Харалика, которые отражают особенности текстуры изображения и в то же время имеют значительно меньшую размерность. В связи с этим исключаются операции свертки в структуре нейронной сети, что значительно сокращает время, затрачиваемое на обучение нейронной сети и диагностику. Для обучения нейронной сети используются реальные изображения листьев для всех болезней растений. Массив исходных данных большого объема, необходимый для обучения, создается с помощью рандомизации.

Ключевые слова: Нормализация фотоизображений, GLCM — матрица, параметры Харалика, цифровые описания изображений листьев, нейронная сеть прямого распространения.

Введение

Цифровой фитомониторинг, который начинает реализовываться в настоящее время в России и во всем мире, требует создания технических и программных средств для автоматизации процессов сбора данных о состоянии посевов в разные фазы роста с помощью беспилотных летательных аппаратов и смартфонов, проведения диагностики заболеваний, в том числе с использованием нейронных сетей. Примеры подходов к решению задачи распознавания состояния растений по изображениям листьев многочисленны [1–14]. Следует выделить две основные труд-

ности при построении систем распознавания: большой объем базы данных классифицированных изображений (dataset) для обучения нейронной сети; а также значительное время на обучение сети и диагностику состояния растений.

Для диагностики заболеваний растений по изображениям листьев с помощью нейронной сети обычно используется числовое описание цвета (например, RGB — изображение, преобразованное в оттенки серого Grayscale). Размер исходного изображения листа пшеницы должен быть не менее 300x100 пикселей (определено в результате обработки большого коли-

чества реальных изображений листьев, при меньшем размере теряются характерные признаки болезней растений), количество градаций яркости в «простых» цифровых фотоаппаратах — 256. Отсюда следует, что цифровое описание одного изображения составляет $300 \times 100 = 30000$ байт.

У каждого сельскохозяйственного растения, например, пшеницы или соевых бобов, количество возможных заболеваний около 15 [15,16]. Для обучения нейронной сети с N возможных заболеваний требуется собрать в базу данных не менее $1000 \times N$ изображений листьев. Очевидно, что эта задача выполнима только в том случае, если она будет решаться в национальном или глобальном масштабе, но даже в этом случае на это уйдет несколько лет.

Рассмотрим основные известные подходы к решению задачи диагностики заболеваний растений по изображениям листьев.

Ananthi S., Varthini S.V [1] предложили программное решение для автоматического обнаружения и расчета текстурной статистики болезней листьев растений. Разработанная схема обработки состоит из четырех основных этапов: сначала создается структура преобразования цвета для входного RGB-изображения, затем зеленые пиксели маскируются и удаляются с использованием определенного порогового значения, затем изображение сегментируется и извлекаются полезные сегменты, наконец, вычисляется статистика текстуры (контраст, энергия, локальная однородность, оттенок кластера, заметность кластера). По статистике текстуры оценивают наличие болезней на листе растения. Экспериментальные результаты на базе данных около 500 листьев растений 30 различных растений подтверждают надежность предложенного подхода.

Kaushal G., Bala R [2] предложили преобразовать входное изображение в шкалу серого, чтобы применить алгоритм GLCM для извлечения признаков, который будет извлекать текстурные признаки, такие как энергия, энтропия и т.д. Эти входные признаки используются для обнаружения болезней растений. Алгоритм кластеризации k-means используется для сегментации входных изображений. Классификатор SVM применяется в существующем алгоритме, который будет классифицировать входное изображение на два класса. Для повышения производительности существующего алгоритма классификатор SVM заменен классификацией KNN. Это приводит к повышению точности обнаружения заболеваний, а также к классификации данных по нескольким классам. Таким образом, обнаружение болезней растений требовало трех основных этапов, а именно: выделения признаков, сегментации и клас-

сификации. В существующей методике алгоритм GLCM используется для извлечения текстурных признаков, кластеризация k-means применяется к входным изображениям сегментов. Классификатор SVM заменен классификатором KNN в предлагаемой работе для классификации данных по нескольким классам, производительность предложенного алгоритма проверена с точки зрения точности и частоты ложных срабатываний с увеличением до 10 процентов по сравнению с существующим методом.

Dhaware C.G., Wanjale K.H. [3]. Предлагаемый подход состоит из четырех основных этапов: получение изображений листьев растений, предварительная обработка изображений, сегментация изображений, извлечение признаков и классификация изображений по различным классам заболеваний. Первичный этап предварительной обработки заключается в изменении размера заданного входного изображения. Начальный размер изображения велик, что занимает больше времени обработки. Таким образом, каждое изображение конвертируется в размеры 512×512 , чтобы избежать значительного времени на проведение диагностики. Следующим этапом является преобразование RGB в HSV. После этого применяются методы сегментации. Сегментация изображения применяется для вычитания фона. Для вычитания фона в основном используются два основных метода: кластерный и цветовой. В предлагаемой системе использовалось кластерное вычитание. При кластерном вычитании фона обнаруживаются связанные элементы изображения. Огромная часть изображения сохраняется, а другая часть удаляется. Метод выделения признаков позволяет извлекать свойства изображения, что может способствовать точной классификации. Для анализа используются корреляция, энергия, однородность и т.д. В предлагаемой статье метод опорных векторов (SVM) используется для классификации изображений. SVM — это контролируемый метод обучения, который обычно применяется для распознавания образов и классификации.

Mahajan V., Dhumale N.R. [4]. В данной статье представлен алгоритм метода сегментации изображений, который используется для автоматического обнаружения и классификации болезней листьев растений. Сегментация изображения использует генетический алгоритм. Он использует нечеткую логику для обнаружения болезней растений. Параметрами являются асимметрия, среднее значение извлечения и отклонение извлечения. Берется тестовое изображение и сравнивается с изображением из базы данных, а затем вычисляется несходство с извлеченными параметрами. Система использует метод Оцу для целей сегментации. Используемые параметры извлечения признаков: среднее значение, стандартное отклоне-

ние, энтропия, стандартное отклонение извлечения, эксцесс извлечения, асимметрия. Система обеспечивает более высокую точность по сравнению с методами, использовавшимися в прошлом. Используя нечеткую логику, он дает точность 88% для обнаружения болезней листьев. Тестируется 57 изображений листьев 3 болезней.

Ashish P., Tanuja P. [5]. Здесь изображение первого листа захватывается и загружается в систему, где это изображение сравнивается с другим изображением, хранящимся в базе данных. Сравнение происходит с помощью алгоритма, который называется алгоритмом гистограммы на основе контента. Для выявления болезней листьев используется обработка изображений. Обработка изображения состоит из извлечения цвета, а затем сравнивается пораженная область. Система помогает принять первоначальные меры предосторожности. Если не позаботиться о надлежащем уходе, это повлияет на качество, количество и, наконец, на производительность. Сегментация выполняется с использованием метода кластеризации К-средних. После того, как изображение сегментировано с помощью метода кластеризации К-средних, значение зеленых пикселей листа маскируется, а затем удаляются эти пиксели с зелеными масками и получается пороговое значение объекта по методу Оцу. Изображениям RGB присваивается нулевое значение для преобразования метода совпадения цветов. В этом методе происходит распределение значений сопутствующих пикселей при заданном смещении, а характеристики листьев извлекаются и сравниваются с соответствующими значениями характеристик, хранящимися в библиотеке. Сегментация выполняется с использованием метода кластеризации К-средних. К-средние классифицируют объекты (пиксели) на основе набора признаков в k-ом. классов. Классификация осуществляется с помощью суммы квадратов расстояний между объектами.

SahayaMerlin M., Thayanandeswari. [6]. В этой статье описан метод выявления и классификации болезней листьев. Сегментация пораженной части выполняется с использованием сегментации К-средних. Затем извлекаются особенности текстуры GLCM и выполняется классификация с использованием SVM. Метод апробирован для выявления болезней листьев цитрусовых.

Несколько других систем распознавания рассматривались в [7–12].

Тутыгин В.С., Басим А.-В. [13, 14] предложили использовать нечеткую логику и расширенный набор ключевых текстурных признаков Харалика в диагностике болезней растений по изображениям листьев.

Заметим, что системы [1–12] позволяют распознавать вид болезни растений при числе болезней не более 5, системы [13–14] способны распознавать до 15 видов болезней растений.

В данной работе предлагается новый, более эффективный метод диагностики болезней растений по изображениям листьев растений, основанный на трехмерных цифровых описаниях изображений листьев растений в виде наборов параметров Харалика в форме изображений в формате png для каждой из цветковых составляющих изображения листьев растений и выполнение классификации с помощью нейронной сети прямого распространения.

В качестве цифрового описания изображения листа растения предлагается использовать набор от 4 до 14 параметров Харалика [17, 18] для нескольких, например, 6 или 8 цветковых компонентов изображения, преобразованных в оттенки серого (Grayscale). Возможные значения параметров Харалика в формате вещественных чисел находятся в диапазоне от 0 до 1, в целочисленном формате — в диапазоне от 0 до 255. Таким образом, общее описание одного изображения будет $(4 \dots 14) * 6 = 24 \dots 84$ байта, что меньше, чем при использовании традиционного подхода, в $1250 \dots 357$ раз. Традиционно 6 цветковых компонент на основе RGB изображения формируются как R, G, B, RG, RB, GB. Мы предлагаем использовать набор из 6 реальных цифровых компонентов: brown, yellow, pale brown, pale gray, almost black, green, типичных для изображений листьев пшеницы с признаками болезней.

Компоненты реальных цветов вычисляются на основе исходных компонентов RGB изображений по формулам:


```
fR = rgb_image(:, :, 1);
fG = rgb_image(:, :, 2);
fB = rgb_image(:, :, 3);
Cj = (r_coef * (1 - abs(fR * 256 - mask_j(1))) /
max(mask_j(1), 255 - mask_j(1))) +
(g_coef * (1 - abs(fG * 256 - mask_j(2))) /
max(mask_j(2), 255 - mask_j(2))) +
(b_coef * (1 - abs(fB * 256 - mask_j(3))) /
max(mask_j(3), 255 - mask_j(3))),
```

где C_j , $j=1,6$, результирующая j-тая цветовая компонента;

```
mask_1=[132 74 54];%brown;
mask_2=[245 228 183];%yellow;
mask_3=[182 146 82];%pale brown;
mask_4=[284 208 193];%pale gray;
mask_5=[56 46 34];%almost black;
```



а



б

Рис. 1. Исходное (А) и нормализованное (В) изображения.

```
mask_6=[0 255 0];%green;
r_coef=0.3;
g_coef=0.59;
b_coef=0.1.
```

Коэффициенты r_coef , g_coef , b_coef подобраны исходя из того, чтобы получить соответствующие цветовые оттенки.

Для первоначального обучения нейронной сети предлагается сформировать набор данных на основе небольших (около 20) реальных изображений листьев, затем усреднить полученные параметры Харалика и добавить случайные нормально распределенные значения с доверительным интервалом, определенным при в процессе обучения нейронной сети по условию достижения заданного уровня правильного диагноза. Используя рандомизацию, можно получить любое количество, например, 1000 различных цифровых описаний для каждой болезни. После этого нейронная сеть будет готова к решению диагностической задачи. Можно дополнять набор и проводить переобучение в процессе работы. Для достижения наилучшего результата распознавания болезней и сокращения времени, затрачиваемого на обучение и диагностику, предлагается предварительно выполнить нормализацию изображения (см. Пример на рис. 1).


Кроме того, при обучении и классификации изображений с помощью нейронной сети предлагается использовать не сами изображения, а их цифровые

описания для каждой цветовой компоненты. На рис. 2 и 3 показаны примеры нормализованных изображений пшеницы и их цифровых описаний, представленных в виде трехмерных графиков, для одной из цветковых компонент изображений


2.1. Моделирование процесса обучения нейронной сети для диагностики болезней растений на основе базового цифрового описания изображений листьев и рандомизации

Нейронная сеть может использоваться для создания системы распознавания болезней растений на основе цифровых описаний.

Чтобы смоделировать процесс обучения, вам необходимо создать набор данных для обучения по принципу, описанному выше. Для этого используются типовые изображения листьев с признаками различных заболеваний, взятые, например, из энциклопедии или справочника [15, 16] или, что лучше, множество, например, 20–40 изображений листьев для каждой болезни. Далее они нормализуются, производится разделение изображений на цветовые компоненты, преобразование цветковых компонентов в полутоновые, формирование матриц GLCM [17] и рассчитываются значения параметров Харалика для всех цветковых компонентов и всех болезней. Если использовалось не одно, а множество изображений для каждой болезни, значения параметров Харалика усредняются. Первые 4 параметра Харалика [17, 18]:



а




б

Рис. 2. Нормализованное изображение листа пшеницы, пораженного болезнью 1, и его цифровое описание в виде трехмерного графика.



а



б

Рис. 3. Нормализованное изображение листа пшеницы, пораженного болезнью 2, и его цифровое описание в виде трехмерного графика.

1) contrast:

$$CN = \frac{1}{(G-1)^2} \sum_{u=0}^{G-1} \sum_{v=1}^{G-1} |u-v|^2 p(u,v);$$

2) correlation

$$CR = \frac{1}{2} \sum_{u=0}^{G-1} \sum_{v=0}^{G-1} \frac{(u-\mu_u)(v-\mu_v)}{\sigma_u^2 \sigma_v^2} p(u,v) + 1;$$

3) energy

$$EN = \sum_{u=0}^{G-1} \sum_{v=0}^{G-1} p(u,v)^2;$$

4) homogeneity

$$HM = \sum_{u=0}^{G-1} \frac{p(u,v)}{1+|u-v|};$$

Таблица 1. Пример матрицы базовых цифровых описаний

	1	2	3	4	5	6
C1con	0,5776	0,1806	0,5259	0,1290	0,2438	0,1963
C1cor	0,6764	0,9462	0,8966	0,9605	0,8891	0,9449
C1en	0,1512	0,1808	0,1141	0,2101	0,2743	0,1659
C1hom	0,7996	0,9128	0,8151	0,9395	0,8930	0,9098
C2con	0,4999	0,1479	0,3784	0,1179	0,2660	0,1672
C2cor	0,6592	0,9469	0,9164	0,9480	0,9346	0,9366
C2en	0,1758	0,2342	0,1307	0,2562	0,1477	0,2284
C2hom	0,8079	0,9272	0,8485	0,9528	0,8780	0,9280
C3con	0,5982	0,1906	0,4516	0,1264	0,3548	0,2196
C3cor	0,5329	0,9095	0,8304	0,9237	0,9117	0,9108
C3en	0,2066	0,2545	0,1667	0,3327	0,1544	0,2159
C3hom	0,7929	0,9096	0,8277	0,9491	0,8484	0,9092
C4con	0,5137	0,1548	0,3867	0,1127	0,2707	0,1761
C4cor	0,6676	0,9441	0,8889	0,9252	0,9319	0,9238
C4en	0,1651	0,2380	0,1430	0,3408	0,1505	0,2871
C4hom	0,8043	0,9239	0,8380	0,9555	0,8760	0,9236
C5con	0,5730	0,1607	0,4828	0,1191	0,2768	0,1800
C5cor	0,6660	0,9494	0,9174	0,9533	0,9319	0,9399
C5en	0,1521	0,2093	0,0874	0,2239	0,1530	0,1919
C5hom	0,7901	0,9216	0,8165	0,9470	0,8762	0,9181
C6con	0,1381	0,0332	0,0200	0,0262	0,0442	0,0191
C6cor	0,7267	0,9073	0,6337	0,8329	0,8801	0,8694
C6en	0,4007	0,6540	0,9070	0,7869	0,5825	0,8193
C6hom	0,9310	0,9834	0,9900	0,9869	0,9779	0,9904

где u, v — координаты матрицы смежности, G — количество уровней серого, μ_u, μ_v, σ_u и σ_v — средние значения и стандартные отклонения строки u и столбца v матрицы.

В результате формируется матрица базового цифрового описания изображений листьев, например, такая, как показано в таблице 1.

Набор данных, большого объема, содержащий, например, 1000 цифровых описаний и необходимый для обучения нейронной сети предлагается создавать на основе данных, содержащихся в матрице базового цифрового описания, и рандомизации, т.е. добавления случайных нормально распределенных значений со значением стандартного отклонения, которое гарантирует правильное распознавание с требуемым уровнем достоверности.

Наборы данных для обучения и проверки формируются по такому же принципу.

2.2. Классификация цифровых описаний изображений листьев с помощью нейронной сети прямого распространения

Для решения задачи идентификации болезни по изображениям листьев растений ранее мы использовали [19] классический подход, основанный на использовании сверточной нейронной сети в практической реализации на Python. [20–23]. Мы выбрали свёрточную нейронную сеть именно потому, что она позволяет нам распознавать визуальные признаки болезни, независимо от того, где они расположены на листе растения. Для этого изображения поступают на вход нейронной сети не в виде одномерного массива, как это было бы с другими типами нейронных сетей, а в виде матрицы пикселей. Такие же матрицы будут получены после свёрточного слоя: они все равно будут иметь пространственную структуру, соответствующую исходному изображению.

Смысл использования свертки в сверточной нейронной сети заключается в извлечении характерных

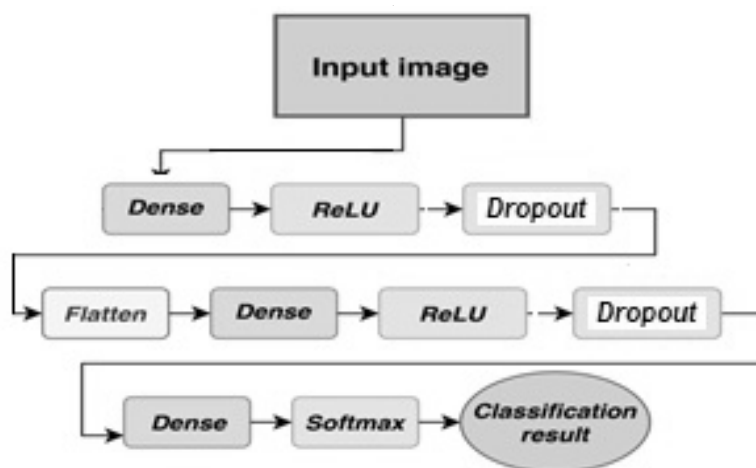


Рис. 4. Структура нейронной сети прямого распространения.

особенностей изображения с одновременным уменьшением его размерности. В описанном в данной статье методе задача классификации — диагностика заболеваний растений по изображениям листьев с помощью нейронной сети прямого распространения решается иначе. Перед обращением к нейронной сети решается задача выявления визуальных признаков болезни на изображениях, инвариантных относительно их расположения на листьях растений. Одновременно решается задача уменьшения размерности цифрового описания изображений. Это достигается за счет использования матрицы GLCM, о которой говорилось выше, и ее описания в форме набора параметров Харалика, которые отражают характерные черты изображения и, в то же время, имеют значительно меньшую размерность. В связи с этим операции свертки в структуре нейронной сети не требуются и вместо сверточной нейронной сети можно использовать более простую нейронную сеть прямого распространения (рис. 4)

Здесь Input image — цифровые описания изображений листьев в виде наборов параметров Харалика для всех цветовых составляющих, приведенные в полутоновые и представленные в виде трехмерных изображений в формате.png

Вторая особенность предлагаемого решения состоит в том, что для обеспечения заданной достоверности полученных результатов диагностики для распознавания предъявляется цифровое описание не одного целевого изображения, а результата усреднения M цифровых описаний. Требуемое количество усреднений M рассчитывается на основе известного выражения для доверительного интервала математического ожидания как

$$M = \frac{D_1^2}{D_2^2}$$

где D_1 — доверительный интервал дисперсии параметров Харалика для целевых изображений, D_2 — доверительный интервал допустимой дисперсии параметров Харалика, обеспечивающий правильное распознавание с заданным уровнем достоверности.

Оценка эффективности системы диагностики болезней листьев растений с помощью нейронной сети проводилась на модельных данных, содержащих 150 цифровых описаний для каждой из 6 болезней пшеницы. Центры распределения значений параметра Харалика рассчитывались для реальных изображений листьев пшеницы. Набор исходных данных для обучения был создан путем добавления нормально распределенной случайной величины со стандартным отклонением 0,048. Полученный набор цифровых описаний в виде изображений в формате.png был размещен в трех массивах: для обучения, валидации и тестирования в соотношении 100: 20: 30 для каждого заболевания. Количество правильных результатов диагностики по данным в массиве, предназначенном для тестирования, составило 97%.

Заключение

1. Необходимым условием корректного распознавания болезней пшеницы с доверительной вероятностью более 0,95 при значительном количестве (до 15) заболеваний является использование параметров Харалика: Contrast, Correlation, Energy, Homogeneity матрицы GLCM для цвето-

вых компонентов. brown, yellow, pale brown, pale gray, almost black, green изображений листьев, нормализация изображений при создании цифровых описаний, нормализация и усреднение параметров целевых изображений, усредненные параметры целевых нормализованных изображений листьев с математическими ожиданиями параметров Харалика для каждой болезни составляют базовое описание болезней.

2. Лучшим инструментом для классификации цифровых описаний нормализованных изображений листьев является нейронная сеть прямого распространения.
3. Набор данных для обучения нейронной сети предлагается создавать на основе усредненных цифровых описаний изображений листьев с признаками всех болезней и применения рандомизации.

4. Использование цифровых описаний нормализованных изображений вместо целевых нормализованных изображений позволяет значительно сократить время, затрачиваемое на обучение нейронной сети и выполнение диагностики.

5. При распознавании целевых изображений для повышения надежности распознавания типа болезни растений необходимо представлять усредненное цифровое описание M-изображений вместо цифровых описаний одного целевого изображения.

6. Достоверность результатов диагностики может быть повышена при расширении списка параметров Харалика эталонного описания или увеличении количества усредненных значений параметров Харалика целевых нормированных фотоизображений листьев.

ЛИТЕРАТУРА

1. Ananthi S., Varthini S.V. Detection and classification of plant leaf diseases // International Journal of Research in Engineering and Applied Sciences. 2012. № 2(2). С. 763–773.
2. Kaushal G., Bala R. GLCM and KNN based Algorithm for Plant Disease Detection // International Journal of Advanced Research in Electrical, Electronics and Computer Science. 2017. № 2(2). С. 1–4.
3. Dhaware C.G., Wanjale K.H. A modern approach for plant leaf disease classification which depends on leaf image processing // 2017 International Conference on Computer Communication and Informatics, ICCCI 2017. 2017. С. 5–8. DOI:10.1109/ICCCI.2017.8117733.
4. Mahajan V., Dhumble N.R. Leaf Disease Detection Using Fuzzy Logic // International Journal of Innovative Research in Science, Engineering and Technology. 2018. № 6(7). С. 6801–6807. DOI:10.15680/IJRSET.2018.0706067.
5. Ashish P., Tanuja P. Survey on Detection and Classification of Plant Leaf Disease in Agriculture Environment // International Advanced Research Journal in Science, Engineering and Technology National. 2017. № 4(4). С. 137–139. DOI:10.17148/iarjset/nciarcse.2017.40.
6. SahayaMerlin M., Thayanandeswari. A novel approach to classify and detect bean diseases based on image processing // ISCAIE2018–2018 IEEE Symposium on Computer Applications and Industrial Electronics. 2018. № 2(2). С. 297–302. DOI:10.1109/ISCAIE.2018.8405488.
7. Jose J., Jayachandran H., George A.S., Jiya S., Pratap A. Haritham: a plant disease identification system // International Journal of Information Systems and Computer Sciences. 2019. № 2(8). С. 18–21.
8. Phadikar S., Sil J., Das A.K. Rice diseases classification using feature selection and rule generation techniques // Computers and Electronics in Agriculture. 2013. (90). С. 76–85. DOI: 10.1016/j.compag.2012.11.001.
9. Shen W., Wu Y., Chen Z., Wei H. Grading method of leaf spot disease based on image processing // Proceedings — International Conference on Computer Science and Software Engineering, CSSE2008. 2008. (6). С. 491–494. DOI:10.1109/CSSE.2008.1649.
10. Zhang S., Zhang C. Orthogonal locally discriminant projection for classification of plant leaf diseases // Proceedings — 9th International Conference on Computational Intelligence and Security, CIS2013. 2013. С. 241–245. DOI:10.1109/CIS.2013.57.
11. Rastogi A., Arora R., Sharma S. Leaf disease detection and grading using computer vision technology & fuzzy logic // 2nd International Conference on Signal Processing and Integrated Networks, SPIN2015. 2015. С. 500–505. DOI:10.1109/SPIN.2015.7095350.
12. Bagde S., Patil S., Patil S., Patil P. Artificial Neural Network Based Plant Leaf Disease Detection // International Journal of Computer Science and Mobile Computing. 2015. № 4(4). С. 900–905.
13. Tutygin V.S., Basim A.-W., Leliuhin D.O. The use of an extended set of key texture features haralick in the diagnosis of plant diseases on leaf images / Vibroengineering PROCEDIA, Vol.25, 39th International JVE Conference in St. Petersburg, Russia, June 25–26, 2019, pp. 122–127
14. Tutygin V.S., Basim A.-W. Plant disease recognition based on multi-dimensional features of leaf RGB images // International Scientific Conference “Telecommunications, Computing and Control” (TELECCON-2019) in St. Petersburg, Russia, 18–19 November 2019
15. Proceedings of International Scientific Conference on Telecommunications, Computing and Control. Smart Innovation, Systems and Technologies, vol 220. Springer, Singapore.
16. М.Койшибаев. Болезни пшеницы. Продовольственная и сельскохозяйственная организация ООН (ФАО), Анкара, 2018. 365с.
17. Йорданка Станчева. Атлас болезней сельскохозяйственных культур. Т. 3., Болезни полевых культур. София — Москва, Изд. ПЕНСОФТ, 2003г
18. Haralick R.M., Dinstein I., Shanmugam K. Textural Features for Image Classification // IEEE Transactions on Systems, Man and Cybernetics. 1973. № 6(SMC-3). С. 610–621. DOI:10.1109/TSMC.1973.4309314.
19. Haralick R.M. Statistical and structural approaches to texture // Proceedings of the IEEE. 1979. № 5(67). С. 786–804. DOI:10.1109/PROC.1979.11328.

20. Тутыгин В.С., Басим Аль-Винди, Рябцев И.А. Система распознавания болезней растений на основе нечёткой логики и нейронных сетей // Современная наука: актуальные проблемы теории и практики. Серия «Естественные и технические науки». № 3, 2019. с. 107–115
21. Николенко С.Н., Кадурич А.А., Архангельская Е.В. Глубокое обучение. Санкт-Петербург, Питер, 2018. 480 с. ISBN:978–5–496–02536–2.
22. Gulli A., Sujit P. Deep Learning with Keras. Moscow: DMK, 2018. 294 с. ISBN:978–5–97060–573
23. Basim Al-Windi, Vladimir Tutygin, Oleg Prokofiev, Sergey Molodyakov. A new approach for diagnosing plant diseases based on 3D digital descriptions of leaf images and neural network 2nd International Conference Cyber-Physical Systems and Control St. Petersburg, Russia • 29 June –2 July 2021.
24. Франсуа Шолле. Глубокое обучение на Python. — СПб.: Питер, 2018. 400 с.: ISBN978–5–4461–0770–4
25. K.K. Thyagarajan¹, I. Kiruba Raji A Review of Visual Descriptors and Classification Techniques Used in Leaf Species Identification. Archives of Computational Methods in Engineering (2019) 26:933–960/ <https://doi.org/10.1007/s11831–018–9266–3>

© Тутыгин Владимир Семёнович, Прокофьев Олег Валерьевич (vs4141@mail.ru).

Журнал «Современная наука: актуальные проблемы теории и практики»



Санкт-Петербургский политехнический университет Петра Великого