

# Нейромоделирование в садоводстве

П. В. Четырбок, А. Н. Казак

Крымский федеральный университет им. В.И. Вернадского

E-petrchetyrbok@gmail.com

**Аннотация.** В статье рассматриваются возможности применения методов искусственного интеллекта в садоводстве для разработки роботизированных комплексов по сбору урожая фруктов и определения заболеваний фруктов с использованием распознавания фотографий плодов с применением машинного обучения нейронных сетей. В настоящее время активно применяются технологии искусственного интеллекта в сельском хозяйстве, которые позволяют эффективно определять урожайность культур, автоматизировать сбор и хранение сельскохозяйственной продукции, определять состояние почвы, определять состав и эффективное использование удобрений, благодаря методам распознавания определять болезни растений, бороться с сорняками.

**Ключевые слова:** садоводство, метод, нейронная сеть, фрукты, машинное обучение

## I. ВВЕДЕНИЕ

Сегодня садоводам следует озадачиться формированием «цифрового двойника» сада, а агрономам – завести цифровой дневник. Ведь нейронным сетям, прежде всего, требуется информация, а её зачастую нет. Искусственный интеллект сначала нужно обучить, только потом он в свою очередь будет подсказывать, что делать. Методы машинного обучения (ML) позволяют обрабатывать большое количество входных данных о развитии растений и на этой основе осуществлять весьма точное прогнозирование урожайности культур [15].

## II. ЦЕЛЬ СТАТЬИ

Целью статьи является рассмотрение основных проблем создания интеллектуальных систем в садоводстве и рассмотрение нейромоделирования как метода их решения. Рассмотрено нейромоделирование с помощью сверточные нейронных сетей (CNN) и нечетких нейронных сетей (НСС).

## III. ОСНОВНАЯ ЧАСТЬ

Методы машинного обучения (ML) позволяют обрабатывать большое количество входных данных о развитии растений и на этой основе осуществлять весьма точное прогнозирование урожайности культур [14]. В одном из исследований авторы разработали систему машинного зрения для уборки вишни [15]. Основная цель этой системы – снижение потребности в ручном труде при уборке урожая и выполнении погрузочно-разгрузочных работ.

Сегодня на рынке представлено несколько интересных садовых решений.

1. Шаттл – универсальная роботизированная платформа для организации внутрисадовой логистики

инвентаря, агрохимии, продуктов и отходов. Робот такой конструкции может решить все логистические сельскохозяйственные задачи, а его работа будет стоить намного дешевле любого трактора. Производители универсальных платформ в России – Дронешуб и Гумич РТК.

2. Уборочный робот для уборки товарных яблок и механического прореживания яблонь. В России робототехнические решения для этой области представлены двумя заводами – ФГБНУ ФНАЦ ВИМ (Москва) и КБНЦ РАН (Кабардино-Балкария).

3. Робот-секатор – универсальный робот для формирующей обрезки, обрезки однолетних конкурентов и ветвей, растущих под острым углом, а также обрезки вертикально растущих ветвей второго порядка (ветка на ветке) и придаточных ветвей, затеняющих крону деревьев. Робот-сборщик легко трансформируется в секатор, он умеет читать скелет дерева, вести свой электронный дневник и четко понимать по скелету дерева, где срезать ветку, а где оставить.

4. Робот-экспедитор – универсальный робот для организации погрузочно-разгрузочных работ. Его задача – взять груз с робота-челнока, сложить его и доставить в машину или на склад.

5–7. Робот-распылитель, робот-разбрасыватель, робот-фертигатор. Первый нужен для защиты сада путем опрыскивания от болезней и вредителей, а также для внекорневых подкормок и химических прореживаний. Второй используется для внесения основных корневых удобрений или яда против грызунов. Третий робот предназначен для дифференцированного полива и внесения удобрений.

8–9. Робот-косилка и робот-мульчер. Робот-косилка предназначен для скашивания травы внутри садового пространства, а робот-мульчировщик выполняет работу по измельчению веток и планировке межсотовых дорог перед уборкой урожая.

10. Робот-прополка для защиты сада от сорняков возле стволов деревьев и удаления лишней корневой системы.

11. Робот-формирователь для привязывания деревьев к шпалерной проволоке резиновым кембриком или металлической скобой, для подвязывания или обламывания боковых основных веток основания в горизонтальном положении.

В России внедрена интеллектуальная система Garden-ЮТ – это система, которая получает информацию из большого количества источников, анализирует ее, дает ответ заинтересованному лицу об оперативной ситуации в садах – с саженцами, техникой, работа. Система позволяет контролировать все производственные

процессы, отслеживать текущее состояние каждого саженца, историю самого саженца и аналитику затрат. Garden-IoT имеет несколько модулей: сады, полив, агрохимическая инспекция, склады с приемкой и выдачей химикатов, удобрений и т. д., задачи, на которых строится отчетность, модуль мониторинга, и отдельно – история саженца/

Нейросеть может отличать здоровое растение от больного. Система в состоянии определить степень угрозы для будущего урожая, предложить способы решения назревшей проблемы. В агропромышленном комплексе Российской Федерации существует большое число задач, решаемых с использованием искусственного интеллекта. Обученная нейронная сеть способна адаптироваться к агроклиматическим особенностям регионов, отдельных рыночных агентов. В условиях цифровой трансформации отрасли для обучения нейронных сетей целесообразно формирование единой национальной базы данных. Экосистема, которую разрабатывает Россельхозбанк для аграрного бизнеса, включает актуальные цифровые решения, определяющие по фотоснимку состояние здоровья плодовых и полевых культур, которые могут быть масштабированы для других видов деревьев и растений. Получение актуальной и объективной информации о состоянии растений с использованием сервисов интернета позволит совершенствовать обмен информацией между специалистами и экспертами-консультантами. Нейросеть как «умный фильтр» можно использовать для сбора и сортировки собранного урожая. При этом производительность труда такого робота гораздо выше эффективности труда человека [15]. По мнению экспертов, для обучения нейронных сетей решению задач АПК необходимо сформировать национальную базу данных, содержащую информацию по функционированию ведущих отраслей с учетом региональных особенностей. Это даст возможность принять правильное управленческое решение в рыночных субъектах цифрового сельского хозяйства, основанных на применении нейрокомпьютерных технологий.

Обнаружение болезней и вредителей растений на основе глубокого обучения сверточных нейронных сетей в настоящее время наиболее эффективно используется в АПК.




Рис. 1. Базовая структура CNN

Сверточные нейронные сети, сокращенно CNN, имеют сложную сетевую структуру и могут выполнять операции свертки [25–37]. Как показано на рис. 1, модель сверточной нейронной сети состоит из входного слоя, слоя свертки, слоя объединения, слоя полного соединения и выходного слоя. В одной модели слой свертки и слой объединения чередуются несколько раз, и

когда нейроны слоя свертки соединены с нейронами слоя объединения, полное соединение не требуется. CNN – популярная модель в области глубокого обучения. Причина кроется в огромной емкости модели и сложной информации, создаваемой базовыми структурными характеристиками CNN, что позволяет CNN играть преимущество в распознавании изображений. В то же время успехи CNN в задачах компьютерного зрения способствовали росту популярности глубокого обучения.

Рассмотрим нейро-нечеткую классификацию изображений на основе нейронной сети NEFCLASS, базовый алгоритм обучения которой предложен в 1994 г. Д. Науком и Р. Крузе. Этот алгоритм обучения реализован в виде нечеткого многослойного персептрона и используется для моделирования систем типа Мамдани. Процесс обучения использует ошибку обучения и может оперировать нечеткими правилами и множествами. Такой метод сохраняет структуру нейронной сети и позволяет интерпретировать систему посредством нечетких множеств. Задачей модели NEFCLASS (NEuro Fuzzy CLASSifier) является получение нечетких правил из множества данных, которые можно разделить на различные классы [13].

Нечеткие множества и лингвистические правила представляют аппроксимацию и определяют результат работы системы NEFCLASS. Они выбираются из множества выборок путем обучения системы, эта система может быть настроена по частичным данным о признаках изображения. Пользователь должен определить количество начальных нечетких множеств и задать значение максимального числа узлов правил, которые могут быть созданы в скрытом слое; для обучения используются функции принадлежности. Преимущества нечеткой логики в том, что появляется возможность работать с неполными, нечеткими данными. Нечеткий вывод строится с помощью правил логического вывода типа «если, то», используя нечеткие множества в виде функций принадлежности. Была рассмотрена базовая модель ННС NEFClass, которая использует треугольные функции принадлежности и эмпирический алгоритм обучения. С целью организации обучения нечеткой нейросети NEFClass был разработан ряд алгоритмов обучения – градиентный, сопряженных градиентов и генетический, приведены исследования их эффективности и сравнение с базовым алгоритмом обучения системы NEFClass, предложенным Д. Науком и Р. Крузе. Применение векторного критерия позволило сократить минимальное количество ошибочно классифицированных образцов [12]. Комбинирую различные методы распознавания изображений на фотографиях фруктов можно достоверно классифицировать заболевания и выдавать рекомендации по их устранению для сельхозпроизводителей [1–11]. В качестве примера рассмотрим интеллектуальный сервис, встроенный в инструмент, по обработке больших данных с помощью модульных нейронных сетей [16]. Рассмотрим возможности оптимальной модульной нейронной сети, топологическая модель которой построена с использованием не только пространства рецепторных и аксоновых полей, но и пространства ошибок, полученного с помощью векторного критерия, для обработки больших данных (Data mining technology). Для самообучения оптимальной модульной сети исследуется построение модулей как нейроагентов.

Векторный критерий позволяет построить оптимальную модульную нейронную сеть для распознавания объектов, исключив из нее модули, которые не влияют на процесс распознавания. То есть в пространстве рецепторов исключаются поля рецепторов, не оказывающие существенное влияние на распознавание объектов по определенному правилу.

Правило исключения модуля из сети следующее: если векторный критерий при распознавании нового объекта на модуле не изменяет своего значения, то этот модуль может быть безболезненно исключен из модульной нейронной сети.

Применяя данное правило, мы фактически строим оптимальную модульную нейронную сеть для распознавания нового объекта. В конкретной реализации нейронной сети с каждым нейронным модулем связаны два линейных векторных пространства:

- пространства рецепторов;
- пространство аксонов.

Добавим к ним еще пространство ошибок. Пространство ошибок содержит вектора ошибок, полученные при распознавании объектов нейронным модулем.

Для нейронного модуля размерность пространства рецепторов равна числу рецепторов, а размерность пространства аксонов равна числу аксонов. То есть нейронный модуль является оператором, который преобразует вектор из пространства рецепторов в пространство аксонов. Оператор можно задать, вводя базисы в векторном пространстве.

Если за базис взять вектора – типичные представители классов объектов из обучающей выборки. Типичный представитель класса объектов выбирается из обучающей выборки среди эталонных образцов объектов этого класса по векторному критерию. А именно выбирается тот эталон, на котором векторный критерий максимален. Векторный критерий позволяет в обучающей выборке среди эталонных образцов выбрать опорные вектора для машины опорных векторов. Также мы сможем добавить еще один базис, а именно вектора, полученные на ошибках распознавания опорных векторов в пространстве ошибок. Исходя из этого базиса, мы сможем вычислить векторный критерий в пространстве ошибок при распознавании нового объекта, и тем самым используя вышеприведенное правило оптимизировать модульную нейронную сеть.

Алгоритм нахождения вектора ошибок произвольного объекта описан в [12]. Модель нейроагента реализуется в виде векторной машины. Пусть задана некоторая машина, которая может классифицировать  $m+1$  классов  $g_0, g_1, \dots, g_m$  (состояния машины – векторные критерии распознавания типичных представителей классов) и натуральный ряд чисел  $N$ . Поставим в соответствие распознаваемому образу  $a_i$  некоторую конфигурацию  $\lambda_i = g_0 a_1 a_2 \dots a_n$ , где  $a_i \in N$ ,  $i=1, 2, \dots, n$ . Если для машины существует вычисление (распознает образ – относит к определенному классу), начинающего в конфигурации  $\lambda_i$  и доходящего до заключительной конфигурации  $\lambda_z$ , то число  $p \in N$ , сопоставляемое  $\lambda_z$ , определяет номер класса. Для машины Тьюринга если не существует такого числа  $p$ , что конфигурация  $\lambda_z$ , является заключительной, то она

работает бесконечно. Для рассматриваемой машины всегда существует число  $p$  (номер класса), что конфигурация  $\lambda_z$ , является заключительной (т. е. всегда найдется класс, к которому машина отнесет распознаваемую конфигурацию  $\lambda_z$ ). Если количество классов ограничено и в класс попадают объекты, значительно отличающиеся по входным параметрам, то необходимо вводить новые классы. Отличающиеся объекты характеризуются векторными критериями, которые выступают векторами меры отличия распознаваемых объектов в пространстве ошибок. Чем меньше векторный критерий, тем хуже распознается объект. Для таких объектов необходимо создавать дополнительные классы с типичными представителями этих объектов. Это можно делать автоматически, выставляя условия для создания класса по векторному критерию, т. е. машина является самообучающейся системой. Машина реализована в виде модуля нейронной сети. Если модули нейронной сети реализовать в виде нейроагентов то получим самообучающую модульную нейронную сеть. Данная сеть не только может оптимизировать свою структуру, но также самообучаться при распознавании новых объектов.

Для того чтобы создать новый класс распознаваемых объектов, необходимо среди векторных критериев найти минимальный  $A$  объект, которому соответствует этот критерий, сделать типичным представителем для нового класса. Таким образом, базис увеличивается на  $1$  и соответственно увеличивается базис в пространстве ошибок. То есть нейроагент сможет классифицировать распознаваемые объекты на большее число классов. Таким образом, происходит самообучение нейроагента. Если самообучение нейроагента останавливается, то тем самым распознаваемые объекты с достаточной точностью классифицируются по существующим классам. То есть, построен алгоритм решения задачи распознавания образов. В отличие от машины Тьюринга этот процесс конечен и тем самым снимается проблема останова. Нейроагент в отличие от машины Тьюринга может построить алгоритмы решения для более широкого круга задач.

#### IV. ЗАКЛЮЧЕНИЕ

В статье рассмотрены основные проблемы создания интеллектуальных систем в садоводстве и предложены методы их решения. Например, совершенно отсутствует явление цифрового двойника сада, нет баз данных по вредителям и болезням для распознавания их искусственным интеллектом. Соответственно, нет точной идентификации и классификации целей и препятствий, данных фитосанитарного контроля. Поэтому уже сегодня садоводам следует озадачиться формированием «цифрового двойника» сада, а агрономам – завести цифровой дневник. Во-первых, для решения проблемы создания качественной базы данных для обучения нейронных сетей распознавания фотографий растений, необходимо создание национальной базы данных с учетом региональных климатических факторов. Во-вторых, для создания приложений, помогающих сельхозпроизводителю определять заболеваемость фруктов, консультировать о методах их устранения, необходимо использовать комбинированные машинные методы обучения, такие как сверточные нейронные сети (CNN) и нечеткие нейронные сети (ННС) [17–24], [38–43].

## СПИСОК ЛІТЕРАТУРЫ

- [1] Zajchenko YU.P. Osnovi proektuvannya intelektual'nih sistem. [Basics of Designing Intelligent Systems]. Textbook. Kiev: Slovo Publ., 2004. 352 p.
- [2] R. Fuller. Introduction to Neuro-Fuzzy Systems. Advances in Soft Computing Series. Springer — Verlag, Berlin, 1999.
- [3] Detlef Nauck. A fuzzy perceptron as a generic model for neuro—fuzzy approaches // Proc. Fuzzy-Systeme'94, Munich, October 1994.
- [4] Nauck D., Kruse. R. NEFCLASS – A Neuro-Fuzzy Approach For The Classification of Data. // Applied Computing, 1995. <http://www.cs.tu-bs.de/~nauck/>.
- [5] Nauck D., Kruse. R. What are Neuro-Fuzzy Classifiers / Proc. Seventh International Fuzzy Systems Association World Congress IFS'97, Vol. IV, pp.228-233, Academia Prague, 1997.
- [6] Nauck D., Nauck U., Kruse R. Generating Classification Rules with the Neuro-Fuzzy System NEFCLASS / Proc. Biennial Conf. of the North American Fuzzy Information Processing Society (NAFIPS'96), Berkeley, 1996.
- [7] Petrosyuk I.M. Zajchenko.YU.P. Porivnyal'nij analiz nejro-nechitkih sistem klasifikacii v umovah info-rmacijnoi nevznachenosti [Comparative Analysis of Neuro-fuzzy Classification Systems under the Conditions of Information Uncertainty]. // NVCH ta optichni informacijni tehnologii. Kiev : Politehnika Publ., 2005. No. 1. pp.22-25.
- [8] Fisher R.A. The use of multiple measurements in taxonomic problems //Annual Eugenics, 7(Part II):179 188, 1936. (also in: Contributions to Mathematical Statistics, Wiley, New York, 1950).
- [9] Zajchenko YU.P., Sevae Fatma, Titarenko K.M., Titarenko N.V. Issledovanie nechetkih nejronnyh setej v zadachah makroekonomicheskogo prognozirovaniya. [Research into Fuzzy Neural Networks in the Macroeconomic Forecasting Context]. // Sistemni doslidzhennya ta informacijni tehnologii. 2004. No. 2. pp.70-86.
- [10] Chetyrbok P.V. Postroenie reshayushchego pravila dlya klassifikacii obrazov na osnove vektorov oshibok [Designing a Decision Rule for Classifying Patterns Based on Error Vectors – Kiev : «Sistemni doslidzhennya ta informacijni tehnologii», 2013. No. 2. pp.114–120.
- [11] Sajmon. Nejronnye seti: polnyj kurs [Neural Networks: Complete Course]. 2nd ed.: Transl. from English. Moscow: Vil'yams Publ., 2006. 1104 p.
- [12] Chetyrbok P.V. Preliminary systemic decomposition of big data for their classification using vector criteria dynamic management model of innovations generations // 2017 XX IEEE International Conference on Soft Computing and Measurements (SCM) , 2017. pp.762–764.
- [13] Зайченко Ю.П., Севае Фатма, Титаренко К.М., Титаренко Н.В. Исследование нечетких нейронных сетей в задачах макроэкономического прогнозирования. // Системні дослідження та інформаційні технології. 2004. №2. С.70-86
- [14] Набоков В.И., Скворцов Е.А., Некрасов К.В. Кадровая проблема и внедрение робототехники в сельском хозяйстве // Финансовая экономика. 2018. № 7. С. 89–91.
- [15] Набоков В.И., Скворцов Е.А., Некрасов К.В. Внедрение робототехники в организациях сельского хозяйства // Вестник ВИЭСХ. 2018. № 4 (33). С. 126–131.
- [16] Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабо связанных нейронных сетей. СПб.: «Политехника», 2014. 328 с.
- [17] Chetyrbok P.V. Artificial Intelligence in Distance Education. Distancionnye obrazovatel'nye tehnologii Materialy III Vserossijskoj nauchno-prakticheskoy konferencii. [Distance Education Technologies. Proceedings of the 3rd All-Russian Scientific and Practical Conference], 2018, pp. 91-95.
- [18] Dorogov A.Ju., Alekseev A.A. Fast Neural Networks // Proceedings of Seventh International Conference on Advanced Computer Systems (ACS-2000) Poland, Szczecin, October 2000. P.267-270.
- [19] Dorogov A.Yu. Parametrical and Topological Plasticity of Multilayer Neural Networks // Processing of 4-th International Conference “New Information Technologies” (NITE'2000) Minsk, Belarus 5-7 December, 2000. Minsk, 2000. Vol. 1. P. 15-19.
- [20] Dorogov A.Yu. Estimation of Multilayer Neural Network Plasticity // Eleventh IF AC International Workshop Control application of optimization CAO'2000 Pergamon An Imprint of Elsevier Science Oxford, UK. 2000. VI. P. 81-85.
- [21] Dorogov A.Ju. Plasticity of Multilayer Neural Network // First international conference on mechatronics and robotics: Proceedings (M&R'2000) St-Petersburg: NPO Omega BF Omega, 2000. May 29-June 2. 2000.V1. P.33-38.
- [22] Chetyrbok P.V. Building a decision rule for the classification of patterns based on error vectors // Systematic advances and information technologies (Kiev), 2013. №2. pp. 114–120.
- [23] Kaplun D., Krasichkov A., Chetyrbok P., ... Garg A., Pannu H.S. Cancer cell profiling using image moments and neural networks with model agnostic explainability: A case study of breast cancer histopathological (breckhis) database. Mathematics, 2021, 9(20).
- [24] Kazak A., Plugatar Y., Johnson J., ... Kaur P., Kokodey T. The Use of Machine Learning for Comparative Analysis of Amperometric and Chemiluminescent Methods for Determining Antioxidant Activity and Determining the Phenolic Profile of Wines Applied System Innovation, 2022, 5(5).
- [25] Ing.H.Ney, B.Leibe. Matching Algorithms for Image Recognition // RWTH Aachen University, Januar, 2010.
- [26] Keiron O'Shea, Ryan Nash. An Introduction to Convolutionan Neural Networks // arXiv:1511.08458v2
- [27] Leon Bottou. Stochastic Gradient Descent Tricks // Neural Networks: Tricks of the Trade. Volume 7700 2012 of the series Lecture Notes in Computer Science. P. 421-436.
- [28] Matthew D.Zeiler, Dilip Krishnan, Graham W. Taylor, Rob Fergus. Deconvolutional Networks // Computer Vision and Pattern Recognition, June 13-18, 2010.
- [29] Samer Hijazi, Rishi Kumar, Chris Rowen. Using Convolutional Neural Networks for Image Recognition. <http://www.cadence.com/en/default.aspx>
- [30] Si Chen, Yufei Wang. Convolutional Neural Networks and Convex Optimization, 2014.
- [31] Son Lam Phung, Abdesselam Bouzerdoum. MATLAB Library for Convolutional Neural Networks. Technical report. <http://www.uow.edu.au/~phung/>
- [32] Tanzila Saba, Amjad Rehman, Ghazali Sulong. Cursive Script Segmentation With Neural Confidence // ICIC International ISSN 1349-4198. P. 4955-4964.
- [33] Vivek Shrivastava, Navdeep Sharma. Artificial Neural Networks Based Optical Character Recognition // Signal & Image Processing: An International Journal (SIPIJ) Vol.3, No.5, October 2012.
- [34] Yangwei Wu, Haohua Zhao, Liqing Zhang. Image Denoising with Rectified Linear Units // Neural Information Processing. 21st International Conference, ICONIP 2014 / Eds. Chu Kiong Loo, Keem Siah Yap, Kok Wai Wong, Andrew Teoh, Kaizhu Huang. Kuching, Malaysia, November 3-6, 2014. P. 142-149.
- [35] Nasonov Andrey, Chesnakov Konstantin, Krylov Andrey. CNN Based Retinal Image Upscaling Using Zero Component Analysis // The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. 2017. Vol. 42. P. 27.
- [36] Page David. How to Train Your ResNet 4: Architecture // Myrtle.ai. 2012. online; accessed: <https://myrtle.ai/learn/how-to-train-your-resnet-4-architecture/> (online; accessed: 15.06.2019).
- [37] Rahimi Ali, Recht Benjamin. Random features for large-scale kernel machines // Advances in neural information processing systems. — 2008. P. 1177–1184. 37
- [38] Rosenblatt Frank. The perceptron: a probabilistic model for information storage and organization in the brain. // Psychological review. 1958. Vol. 65, no. 6. P. 386.
- [39] Saunders Craig, Gammerman Alexander, Vovk Volodya. Ridge regression learning algorithm in dual variables. 1998.
- [40] Simonyan Karen, Zisserman Andrew. Very deep convolutional networks for large-scale image recognition // arXiv preprint arXiv:1409.1556. 2014.
- [41] Walz Guido. Computing the matrix exponential and other matrix functions // Journal of computational and applied mathematics. 1988. Vol. 21, no. 1. P. 119–123.
- [42] Jaehoon Lee, Lechao Xiao, Samuel Schoenholz et al. Wide neural networks of any depth evolve as linear models under gradient descent // Advances in neural information processing systems. 2019. P. 8570–8581.
- [43] Md Zahangir Alom The history began from alexnet: A comprehensive survey on deep learning approaches / Md Zahangir Alom, Tarek M Taha, Christopher Yakopcic et al. // arXiv preprint arXiv:1803.01164. 2018.