

## Использование сверточных нейронных сетей для задач автоматического обнаружения заболеваний

М. А. Шереужева<sup>1,2</sup>, М. А. Шереушев<sup>3</sup>, З. М. Альбекова<sup>4</sup>

<sup>1</sup>Институт информатики и проблем регионального управления – филиал Кабардино-Балкарского научного центра Российской академии наук  
360000, Россия, г. Нальчик, ул. И. Арманд, 37-а

<sup>2</sup>Московский государственный технологический университет «СТАНКИН»  
127055, Россия, Москва, Вадковский пер., 1

<sup>3</sup>Московский государственный технический университет имени Н. Э. Баумана  
105005, Россия, Москва, ул. Бауманская, 5

<sup>4</sup>Институт цифрового развития, Северо-Кавказский федеральный университет  
350029, Россия, г. Ставрополь, пр. Кулакова, 2

**Аннотация.** В данной статье представлен обзор существующих архитектур сверточных нейронных сетей и их применения в задаче классификации для обнаружения заболеваний плодов и растений. Заболевания растений и плодов являются серьезной проблемой в сельском хозяйстве и садоводстве, их раннее обнаружение может помочь в принятии своевременных мер по предотвращению распространения и минимизации ущерба. Результаты исследования могут быть полезны для разработки автоматизированных систем обнаружения заболеваний плодов и растений, что способствует повышению урожайности.

**Ключевые слова:** нейронные сети, машинное обучение, архитектура сверточной сети, компьютерное зрение, классификация изображений

Поступила 25.09.2023, одобрена после рецензирования 06.10.2023, принята к публикации 09.10.2023

**Для цитирования.** Шереужева М. А., Шереушев М. А., Альбекова З. М. Использование сверточных нейронных сетей для задач автоматического обнаружения заболеваний // Известия Кабардино-Балкарского научного центра РАН. 2023. № 5(115). С. 41–51. DOI: 10.35330/1991-6639-2023-5-115-41-51

MSC: 68T99

Review article

## The use of convolutional neural networks for automatic diseases detection tasks

M.A. Shereuzheva<sup>1,2</sup>, M.A. Shereuzhev<sup>3</sup>, Z.M. Albekova<sup>4</sup>

<sup>1</sup>Institute of Computer Science and Problems of Regional Management – branch of Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences  
360000, Russia, Nalchik, 37-a I. Armand street

<sup>2</sup>Moscow State Technological University «STANKIN»  
127055, Russia, Moscow, 1 Vadkovsky lane

<sup>3</sup>Moscow State Technical University named after N. E. Bauman  
105005, Russia, Moscow, build. 5 corps 1 Baumanskaya street

<sup>4</sup>Institute of Digital Development, North Caucasian Federal University  
350029, Russia, Stavropol, 2 Kulakov avenue

**Abstract.** This article provides an overview of existing convolutional neural network architectures and their application in the classification task for detecting diseases of fruits and plants. Diseases of plants and fruits are a serious problem in agriculture and horticulture, and their early detection can

help in taking timely measures to prevent the spread and minimize damage. The results of the study can be useful for the development of automated systems for detecting diseases of fruits and plants, which helps to increase yields.

**Keywords:** neural networks, machine learning, convolutional network architecture, computer vision, image classification

Submitted 25.09.2023,

approved after reviewing 06.10.2023,

accepted for publication 09.10.2023

**For citation.** Shereuzheva M.A., Shereuzhev M.A., Albekova Z.M. The use of convolutional neural networks for automatic diseases detection tasks. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2023. No. 5(115). Pp. 41–51. DOI: 10.35330/1991-6639-2023-5-115-41-51

## ВВЕДЕНИЕ

Одной из первостепенных задач исследований в области распознавания дефектов и заболеваний плодов и растений является обеспечение своевременного обнаружения таких состояний после обнаружения самого плода [1, 2]. Это важно по следующим причинам:

- повышение плодородности почвы и как следствие увеличение урожайности [3];
- снижение вероятности получения продукции низкого качества.

Для решения задачи требуется использовать специально обученную нейронную сеть, которая будет локализовать и анализировать возможные заболевания плодовых культур и растений на основе внешних признаков. Сверточные нейронные сети подходят для этой цели. Они также создадут статистические данные для выявления закономерностей развития и распространения заболеваний.

Сверточные нейронные сети (Convolutional Neural Networks, CNN) представляют собой мощный класс архитектур искусственных нейронных сетей, широко применяемых для решения задач классификации в области компьютерного зрения. Они обладают способностью эффективно анализировать и обрабатывать входные данные, такие как изображения, с учетом их пространственной структуры.

Архитектуры сверточных нейронных сетей были разработаны с идеей эмуляции визуальной коры головного мозга человека, которая обрабатывает визуальные сигналы. Они способны автоматически извлекать признаки из входных данных, иерархически агрегировать их и принимать решение о классификации на основе этих признаков.

Одним из ключевых элементов сверточных нейронных сетей являются сверточные слои, которые выполняют операцию свертки между входными данными и набором фильтров [4]. Свертка позволяет выделять локальные пространственные шаблоны и признаки в изображениях, что делает сверточные нейронные сети особенно эффективными для задач компьютерного зрения.

Другой важный компонент архитектур сверточных нейронных сетей – слои пулинга (pooling layers). Они выполняют операцию уплотнения и уменьшения размерности данных, что позволяет сети справляться с более высокой степенью инвариантности к малым изменениям входных данных, таким как сдвиги или небольшие искажения.

В последние годы было предложено множество различных архитектур сверточных нейронных сетей, которые достигли впечатляющих результатов в задачах классификации изображений. Некоторые из наиболее известных архитектур включают в себя CNN, ResNet, DenseNet121, Mobilenet V2, Inception architecture, EfficientNet и другие. Каждая из этих архитектур имеет свои особенности и характеристики, которые позволяют им достигать высокой точности и эффективности в различных задачах классификации.

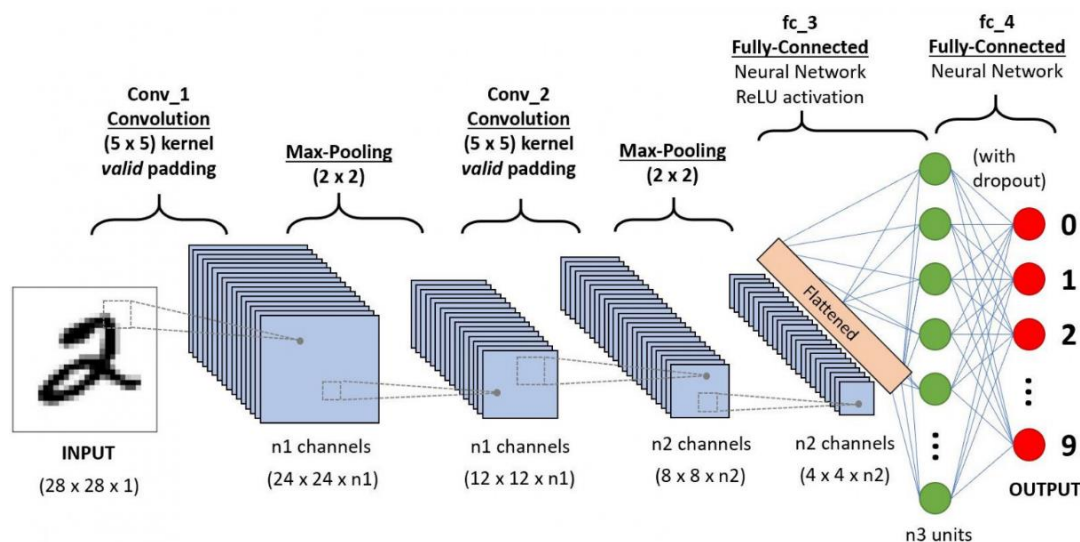
Целью данной работы является исследование основных архитектур сверточных нейронных сетей.

Для решения поставленной цели необходимо решить следующие задачи:

- рассмотреть различные архитектуры сверточных сетей;
- изучить основные компоненты и принципы работы нейронных сетей;
- сравнить рассмотренные архитектуры.

### СПОСОБЫ АВТОМАТИЧЕСКОГО ОБНАРУЖЕНИЯ ЗАБОЛЕВАНИЙ CNN

Рассмотрим подробно архитектуры сверточных нейронных сетей (CNN), применяемые в области компьютерного зрения, которые являются частью машинного обучения. Структура CNN аналогична связям в зрительной коре человеческого мозга. Одним из преимуществ CNN является их способность извлекать объекты изображений без необходимости ручного извлечения, которое требуется в некоторых других методах машинного обучения. Из-за этих преимуществ в течение последнего десятилетия CNN успешно применялись для автоматизированного контроля дефектов литья с различными характеристиками [5, 6]. В процессе развития CNN было создано множество архитектур, которые прошли структурные преобразования, регуляризацию, оптимизацию параметров и другие улучшения. Одной из выдающихся архитектур CNN является AlexNet, которая успешно справляется с задачами распознавания изображений. Хотя CNN показывают лучшие результаты в области обработки изображений по сравнению с традиционными методами машинного обучения, все же остаются некоторые общие проблемы, связанные с ограниченной обобщаемостью моделей. В частности, модели, обученные на одном наборе данных с определенным распределением объектов, значительно снижают свою производительность при тестировании на другом наборе данных с другим распределением объектов. На рисунке 1 показан принцип работы алгоритмов на основе архитектуры CNN.



*Рис. 1. Схема слоев архитектуры CNN*

*Fig. 1. CNN architecture layer diagram*


### RESNET

Более глубокие нейронные сети сложнее обучать. Авторы [7] представили структуру остаточного обучения, чтобы облегчить обучение сетей с большей глубиной по сравне-

нию с предыдущими моделями. Эта архитектура показана на рисунке 2, где различные размеры протекающих тензоров обозначены разными цветами. При переходе от одного цвета к другому количество каналов увеличивается в 2 раза, а ширина и высота тензора уменьшаются в 2 раза благодаря параметру  $\text{stride} = 2$ . Дугообразные стрелки представляют собой идентичное отображение без изменений размера тензора, а пунктирные стрелки указывают на изменение размера.

Первый слой – свертка  $7 \times 7$ , за ней идет  $\text{max}$ -пулинг, а потом ровный строй сверток  $3 \times 3$  (почти во всех  $\text{stride} = 1$ , кроме тех, что на стыке цветов, – в них  $\text{stride} = 2$ ). И в самом конце стоят  $\text{global average pooling}$  и полносвязный слой. Пулинг считает среднее значение для каждого канала в тензоре, а полносвязный слой отображает эти значения.

Для более глубоких сетей (50+ слоев) использовали  $\text{residual block}$ , известный как «bottleneck» (бутылочное горлышко). Первая свертка  $1 \times 1$  в бутлнеке уменьшает количество каналов, затем идет свертка  $3 \times 3$  и в конце опять  $1 \times 1$ , которая возвращает исходное количество каналов. Этот трюк позволяет увеличить глубину сети без сильного увеличения количества параметров.



*Рис. 2. Архитектура ResNet*


*Fig. 2. ResNet architecture*

Центральное значение для многих задач визуального распознавания имеет глубина представлений. Это убедительно доказывает применимость, по мнению авторов, принципа остаточного обучения к другим задачам компьютерного зрения.

## DENSENET121

Исследования, проведенные авторами работы по ResNet, показали, что сверточные сети могут быть глубже, точнее и эффективнее в обучении, если между слоями содержатся короткие соединения, которые связывают слои, близкие к входу, со слоями, близкими к выходу. В своей статье [8] авторы учли это наблюдение и представили плотную сверточную сеть (Dense Net). В Dense Net каждый слой соединен с любым другим слоем прямыми связями. В отличие от традиционных сверточных сетей с  $L$  слоями, которые имеют только одно соединение между каждым слоем и его последующим слоем, эта сеть имеет  $L(L + 1)/2$  прямых соединений. Каждый слой в Dense Net использует карты объектов всех предыдущих слоев в качестве входных данных, а его собственные карты объектов используются в качестве входных данных для всех последующих слоев. Плотные сети обладают несколькими преимуществами: они решают проблему исчезающего градиента, улучшают распространение объектов, способствуют повторному использованию объектов и значительно сокращают количество параметров [9].

На рисунке 3 показана архитектура сети DenseNet. Показан один блок DenseNet с пятью слоями. На вход слоя поступают карты признаков от предыдущих слоев.



**Рис. 3.** Принцип работы DenseNet, а именно описание взаимодействия слоев

**Fig. 3.** The operating principle of DenseNet, namely the description of the interaction of layers

DenseNets естественным образом объединяют свойства сопоставления идентификационных данных, глубокого контроля и разнообразной глубины в соответствии с простым правилом подключения [8]. Это позволяет эффективно повторно использовать функции во всех сетях и создавать более компактные и точные модели. Благодаря их компактным внутренним представлениям и уменьшенной избыточности функций DenseNets являются превосходным средством извлечения объектов для различных задач компьютерного зрения, основанных на сверточных функциях.

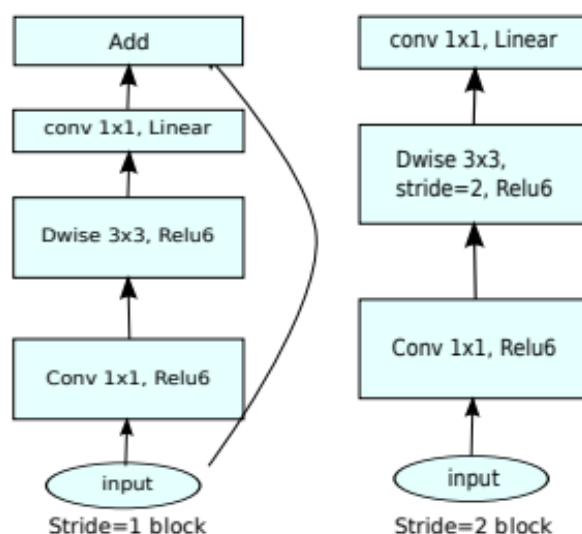
### MOBILENET V2

В 2017 году была представлена семья нейронных сетей компьютерного зрения под названием MobileNetV1. Эти сети были разработаны с учетом мобильных устройств и предназначены для поддержки различных задач, таких как классификация, обнаружение и другие. Возможность выполнения глубокого обучения на персональных мобильных устройствах обеспечивает удобство для пользователей, позволяя им иметь доступ в любое время и в любом месте, а также предлагает дополнительные преимущества в области безопасности, конфиденциальности и энергопотребления. С развитием новых приложений, позволяющих пользователям взаимодействовать с реальным миром в режиме реального времени, возникает потребность в еще более эффективных нейронных сетях.

MobileNetV2 является сверточной нейронной сетью, которая улучшает производительность современных моделей для мобильных устройств в различных задачах и тестах. Она преимущественно применяется на мобильных устройствах. Этот подход зарекомендовал себя очень хорошо и обладает высокой точностью распознавания при отличной скорости работы [10].

Принцип работы MobileNetV2 основан на перевернутой остаточной структуре, где короткие соединения присутствуют между тонкими слоями «бутылочного горлышка». Промежуточный уровень расширения использует облегченные свертки по глубине для фильтрации объектов в качестве источника нелинейности. Кроме того, важно устранить нелинейности в узких слоях, чтобы сохранить репрезентативную силу. Авторы отметили, что это способствует улучшению производительности.

Основная идея сети MobileNetV2 заключается в использовании функционального блока, аналогичного тому, что применяется в MobileNetV1. Этот сверточный слой может выполняться с шагом один или с шагом два. На рисунке 4 справа показан блок с шагом два, а слева – с шагом один. Блок справа имеет короткие соединения для снижения размерности.



*Рис. 4. Сеть MobileNet*

*Fig. 4. MobileNet network*

Рассмотрим глубокую нейронную сеть с  $n$  слоями. Каждый слой имеет активационный тензор размерности  $h_i \times w_i \times d_i$ . Когда мы подаем набор изображений на вход сети, активации слоя формируют разнообразие, которое имеет интерес для нас. Ранее считалось, что это разнообразие может быть встроено в низкоразмерные подпространства. Информация, содержащаяся в отдельных пикселях глубокого сверточного слоя, закодирована в их значениях. Фактически эта информация находится в некотором многообразии, которое встраивается в низкоразмерное подпространство (рис. 5).

На первый взгляд, мы могли бы просто уменьшить размерность слоя, чтобы уменьшить размерность рабочего пространства. Это было успешно применено в MobileNetV1 с использованием параметра множителя ширины, который обеспечивает эффективный баланс между вычислительной эффективностью и точностью, и включено в эффективные модели других сетей. Следуя этой логике, подход с множителем ширины позволяет уменьшить размерность пространства активаций до тех пор, пока интересующее нас разнообразие не будет охватывать все это пространство. Однако этот подход перестает работать, когда применяется нелинейная функция ReLU. С другой стороны, если многообразие на входе может быть встроено в значительно более низкоразмерное подпространство пространства активаций, то функция ReLU сохраняет информацию, внося необходимую сложность в набор выражаемых функций.

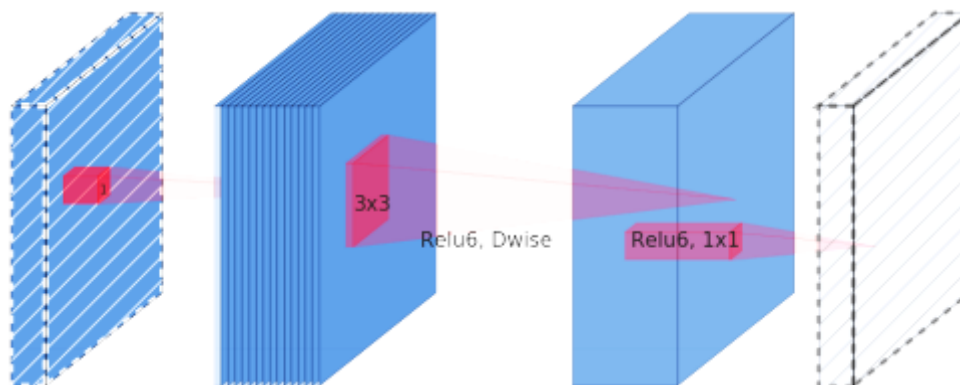
Подводя итог, авторы выделяют два свойства, которые указывают на то, что интересующее нас разнообразие находится в низкоразмерном подпространстве многомерного пространства активаций:

1. Если многообразие остается ненулевым после применения функции ReLU, это соответствует линейному преобразованию.

2. Функция ReLU способна сохранять полную информацию о входном многообразии, но только если оно находится в низкоразмерном подпространстве входного пространства.



Исходя из этих двух идей можно сделать эмпирическое предположение о низкоразмерности интересующего нас многообразия для оптимизации существующих нейронных архитектур. Можно фиксировать это, добавляя линейные слои узкого прохода в сверточные блоки. Экспериментальные данные показывают, что использование линейных слоев имеет решающее значение, поскольку это предотвращает потерю слишком большого объема информации из-за нелинейных преобразований. Удаление нелинейности позволяет повысить производительность.



*Рис. 5. Выборка сверточного алгоритма архитектуры MobileNet*

*Fig. 5. Sampling of the convolutional algorithm of the MobileNet architecture*

#### INCEPTION ARCHITECTURE

В работе [11] была исследована возможность масштабирования сетей с использованием факторизованных сверток и регуляризации для наиболее эффективного использования вычислительных ресурсов. Авторы представили Inception-блок, который значительно снижает вычислительные затраты по сравнению с VGGNet и его более производительными версиями. Это позволяет использовать начальные сети в сценариях с обработкой больших объемов данных или на устройствах с ограниченной памятью и вычислительными ресурсами, таких как мобильные устройства. Хотя существуют специализированные решения для оптимизации использования памяти и выполнения операций, они могут добавить сложности. Кроме того, эти методы могут быть применены и для оптимизации начальной архитектуры, что увеличивает эффективность.

Авторы вывели несколько принципов проектирования, основанных на обширных экспериментах с различными архитектурами сверточных сетей. Отклонение от этих принципов часто приводило к ухудшению качества сетей, а их соблюдение улучшало архитектуру в целом. Вот эти принципы:

1. Избегайте узких мест в представлении, особенно на ранних этапах работы сети. Представления сетей прямой связи должны иметь постепенное уменьшение размерности от входных данных к выходным, чтобы избежать экстремального сжатия. Размер представления не может быть оценен просто по его размерности.

2. Представления с более высокой размерностью легче обрабатывать внутри сети.

3. Пространственная агрегация может быть выполнена на вложениях меньшей размерности без значительной потери репрезентативной мощности. Например, перед более развернутой сверткой можно уменьшить размерность входного представления без серьезных побочных эффектов.

4. Сбалансируйте ширину и глубину сети. Оптимальная производительность сети достигается, если количество фильтров и глубина сети сбалансированы. Увеличение и ши-

рины, и глубины сети может улучшить ее качество, но оптимальное улучшение при фиксированном вычислительном бюджете достигается, если они увеличиваются параллельно. Поэтому вычислительные ресурсы должны быть распределены сбалансированно между шириной и глубиной сети.

Авторы предоставили эти принципы проектирования для масштабирования сверточных сетей и изучили их в контексте начальной архитектуры. Эти принципы позволяют создавать высокопроизводительные сети классификации с относительно низкими вычислительными затратами по сравнению с более простыми и монолитными архитектурами, такими как VGGNet. Они также отметили, что эти принципы могут быть применены для оптимизации не только начальных архитектур, но и уже существующих.

Таким образом, факторизованные свертки и регуляризация являются эффективными методами оптимизации сверточных сетей, которые позволяют улучшить производительность сети при ограниченных вычислительных ресурсах. Эти методы основаны на принципах проектирования, которые позволяют избежать узких мест в представлении, сбалансировать ширину и глубину сети, а также выполнить пространственную агрегацию на вложениях меньшей размерности.

Однако стоит отметить, что масштабирование сверточных сетей – это активная область исследований, и появляются новые методы и архитектуры сетей, которые могут быть эффективными для оптимизации производительности и использования ресурсов. Поэтому всегда полезно быть в курсе последних исследований и экспериментировать с различными методами и архитектурами для достижения оптимальных результатов.

#### EFFICIENTNET

В работе [12] авторы представили новую базовую сеть и ее масштабирование, используя поиск по нейронной архитектуре. Они создали семейство моделей, называемых эффективными сетями, которые показывают высокую точность и эффективность по сравнению с предыдущими сетями. Особенно эффективная модель Net-B7 достигает точности 84,3 % top-1 в ImageNet, при этом она в 8,4 раза меньше и работает в 6,1 раза быстрее по сравнению с лучшими существующими сверточными нейронными сетями.

Сравнение результатов работы EfficientNet с другими алгоритмами приведено на рисунке 6 ниже.




Рис. 6. Пример результатов EfficientNet (выделена красным) относительно других алгоритмов

Fig. 6. Example of EfficientNet results (highlighted in red) relative to other algorithms



В своей статье исследователи провели систематическое изучение масштабирования EfficientNet и пришли к выводу, что важным, но недостающим аспектом, препятствующим повышению точности и эффективности, является тщательный баланс между шириной, глубиной и разрешением сети. Для решения этой проблемы был предложен простой и эффективный метод комплексного масштабирования, который позволяет легко адаптировать базовую сеть EfficientNet в соответствии с заданными ограничениями ресурсов. При этом метод сохраняет эффективность модели. С использованием этого метода было показано, что сетевая модель, эффективная для мобильных устройств, может быть масштабирована очень эффективно, превосходя самые современные показатели точности при использовании меньшего количества параметров.

#### СРАВНЕНИЕ РАССМОТРЕННЫХ АРХИТЕКТУР

Таблица 1 для наглядного сравнения рассмотренных архитектур. В качестве примера взяты листья яблок, томатов и винограда. Таблица представляет собой метрику, которая показывает, насколько точно сеть может классифицировать изображения листьев или различных плодов и определять наличие заболеваний.

**Таблица 1.** Сравнение точности сверточных нейронных сетей

**Table 1.** Comparison of accuracy of convolutional neural networks

Описание	Название	Точность
Для обнаружения заболеваний на листьях яблок	DenseNet121	95%
Для обнаружения заболеваний яблок и томатов по листьям	Mobilenet V2	95%
	InceptionV3	97%
	EfficientNet	98%
Для обнаружения заболеваний яблок, томатов и винограда по листьям	GoogleNet	73%
	CNN самодельная сеть	92%
	ResNet	99.2%

EfficientNet и ResNet продемонстрировали наивысшую точность при классификации заболеваний растений. Одну из этих моделей можно использовать в качестве основы для распознавания дефектов плодов и растений.

#### ЗАКЛЮЧЕНИЕ

В данной статье подробно рассмотрены архитектуры сверточных нейронных сетей для задачи классификации. Были изучены основные концепции и компоненты сверточных нейронных сетей, такие как сверточные слои, слои объединения, полносвязные слои и функции активации.

Результаты исследования подтверждают значимость и перспективность использования сверточных нейронных сетей в области обнаружения заболеваний плодов и растений. Дальнейшее развитие и оптимизация архитектур сверточных нейронных сетей могут привести к созданию более эффективных и точных систем, способных справляться с разнообразными заболеваниями и улучшать процессы в сельскохозяйственной и садоводческой отраслях.

## REFERENCES

1. Digital agriculture [Электронный ресурс]. URL: [https://en.wikipedia.org/wiki/Digital\\_agriculture](https://en.wikipedia.org/wiki/Digital_agriculture).
2. Шереужева М. А., Шереужев М. А. Разработка экспертных систем для повышения эффективности выращивания растений в сельском хозяйстве // Известия Кабардино-Балкарского научного центра РАН. 2022. № 5(109). С. 93–104. DOI: 10.35330/1991-6639-2022-5-109-93-104.  
Shereuzheva M.A., Shereuzhev M.A. Development of expert systems to improve the efficiency of growing plants in agriculture. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2022. No. 5(109). Pp. 93–104. DOI: 10.35330/1991-6639-2022-5-109-93-104. (In Russian)
3. Нагоев З. В., Шуганов В. М., Бжихатлов К. Ч. и др. Перспективы повышения производительности и эффективности сельскохозяйственного производства с применением интеллектуальной интегрированной среды // Известия Кабардино-Балкарского научного центра РАН. 2021. № 6(104). С. 155–165. DOI: 10.35330/1991-6639-2021-6-104-155-165.  
Nagoev Z.V., Shuganov V.M., Bzhikhatlov K.Ch. et al. Prospects for increasing the productivity and efficiency of agricultural production with the use of an intelligent integrated environment. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2021. No. 6(104). Pp. 155–165. DOI: 10.35330/1991-6639-2021-6-104-155-165. (In Russian)
4. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2012. 60(6). Pp. 84–90.
5. Pushkarev A., Yakubailik O. A web application for visualization, analysis, and processing of agricultural monitoring spatial-temporal data. *CEUR Workshop Proceedings*. 2021. Vol. 3006. Pp. 231–237. URL: [http://ceur-ws.org/Vol-3006/27\\_short\\_paper.pdf](http://ceur-ws.org/Vol-3006/27_short_paper.pdf)
6. Скворцов Е. А., Скворцова Е. Г., Санду И. С. и др. Переход сельского хозяйства к цифровым, интеллектуальным и роботизированным технологиям // Экономика региона. 2018. Т. 14. № 3. С. 1014–1028.  
Skvortsov E.A., Skvortsova E.G., Sandu I.S. et al. Transition of Agriculture to Digital, Intellectual and Robotics Technologies. *Ekonomika regiona* [Economy of Region]. 2018. Vol. 14. No. 3. Pp. 1014–1028. (In Russian)
7. He K. et al. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. Pp. 770–778.
8. Iandola F. et al. Densenet. Implementing efficient convnet descriptor pyramids. *arXiv preprint arXiv*. 2014. Pp. 1404–1869.
9. Huang G., Liu Z., Van Der Maaten et al. Connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017. Pp. 4700–4708.
10. Sandler M., Howard A., Zhu M. et al. MobileNetV2. Inverted residuals and linear bottlenecks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018. Pp. 4510–4520.
11. Szegedy C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning. *Thirty-first AAAI conference on artificial intelligence*. 2017.
12. Tan M., Le Q. Efficientnet. Rethinking model scaling for convolutional neural networks. *International conference on machine learning*. PMLR. 2019. Pp. 6105–6114.

### Информация об авторах

**Шереужева Милана Артуровна**, магистр кафедры «Информационные технологии и вычислительные системы», Московский государственный технический университет «СТАНКИН»; 127055, Россия, Москва, Вадковский пер., 1;

стажер-исследователь лаборатории «Интеллектуальные среды обитания», Институт информатики и проблем регионального управления – филиал Кабардино-Балкарского научного центра РАН; 360000, Россия, г. Нальчик, ул. И. Арманд, 37-а;  
milana.shereuzheva2001@mail.ru, ORCID: <https://orcid.org/0000-0002-6668-4703>

**Шереужев Мадин Артурович**, ст. преподаватель кафедры «Робототехнические системы и мехатроника», Московский государственный технический университет имени Н. Э. Баумана; 105005, Россия, Москва, улица 2-я Бауманская, 5, корп. 1;  
shereuzhev@gmail.com, ORCID: <https://orcid.org/0000-0003-2352-992X>

**Альбекова Замира Мухамедалиевна**, канд. пед. наук, доцент кафедры информационных систем и технологий, Институт цифрового развития, Северо-Кавказский федеральный университет; 350029, Россия, г. Ставрополь, пр-т Кулакова, 2;  
zalbekova@ncfu.ru; ORCID: <https://orcid.org/0000-0002-7214-8114>

### Information about the authors

**Shereuzheva Milana Arturovna**, master, Department “Information technologies and computing systems”, Moscow Technical University “STANKIN”;

127055, Russia, Moscow, 1 Vadkovsky lane;

trainee researcher of the Laboratory “Intellectual Habitats” of the Institute of Computer Science and Problems of Regional Management – branch of Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences;

360000, Russia, Nalchik, 37-a I. Armand street;

milana.shereuzheva@mail.ru, ORCID: <https://orcid.org/0000-0002-6668-4703>

**Shereuzhev Madin Arturovich**, senior lecturer, Department “Robotic systems and mechatronics”, Moscow State Technical University named after N.E. Bauman;

105005, Russia, Moscow, build. 5 corps 1 Baumanskaya street;

shereuzhev@bmtu.ru, ORCID: <https://orcid.org/0000-0003-2352-992X>

**Albekova Zamira Mukhamedalieвна**, Candidate of Pedagogical Sciences, Associate Professor, Department of Information Systems and Technologies, Institute of Digital Development, North Caucasus Federal University;

350029, Russia, Stavropol, 2 Kulakov avenue;

zalbekova@ncfu.ru, ORCID: <https://orcid.org/0000-0002-7214-8114>