

УДК 004.9

ПРОГНОЗИРОВАНИЕ ИНДЕКСОВ ВЕГЕТАТИВНОСТИ С ИСПОЛЬЗОВАНИЕМ СПУТНИКОВЫХ СНИМКОВ

© 2024 Н.А. Андриянов

Финансовый университет при Правительстве Российской Федерации, г. Москва, Россия

Статья поступила в редакцию 06.07.2024

В настоящей работе представлено решение задачи прогнозирования вегетативности на основе моделей временных рядов. При этом особое внимание уделяется разработке фильтра изображений с повышенной облачностью. Получена точность классификации искаженных снимков выше 95% на базе сверточных нейронных сетей. Корень среднеквадратичной ошибки прогнозирования NDVI с использованием ансамбля нейронных сетей меньше 0,1. Показано, как можно использовать разработанные алгоритмы для дифференцированного внесения удобрений. Представлены выражения для расчета NDVI и методики для слгаживания индексов в случае пропуска данных и фильтрации облачных снимков. Полученные в работе результаты могут быть полезны специалистам, занимающимся обработкой данных дистанционного зондирования Земли из космоса, а алгоритмы фильтрации облачных снимков могут быть использованы и при решении других прикладных задач, как, например, мониторинг пожаров.

Ключевые слова: нейронные сети, аэрокосмическая съемка, спутниковый мониторинг, индекс вегетативности, обработка изображений.

DOI: 10.37313/1990-5378-2024-26-4(3)-329-339

EDN: KMEBGQ

ВВЕДЕНИЕ

В настоящее время множество прикладных задач интеллектуального анализа изображений и данных решается с использованием съемки земной поверхности в различных частотных спектрах [1–4]. Выходными данными в результате такой регистрации Земли являются массы многомерных изображений, которые в отличие от оптических снимков содержат не три цветных канала, а большее количество слоев по определенным частотным спектрам. Вплоть до начала 2010-х годов важную роль при обработке таких изображений играли алгоритмы, основывающиеся на авторегрессионных многомерных случайных полях [5–8].

Тем не менее, в последнее время такие модели применяются реже и реже. На смену им пришли технологии на основе искусственных нейронных сетей [9–11]. В последние годы также наблюдается высокий интерес к задачам автоматизации сельского хозяйства с использованием подобного рода данных. Для построения эффективных систем точного земледелия сегодня можно использовать данные о погоде, вносимых удобрениях, а также получать оценки вегетативности участков Земли с помощью аэрокосмической или спутниковой съемки.

Андриянов Никита Андреевич, кандидат технических наук, доцент кафедры искусственного интеллекта.
E-mail: nikita-and-nov@mail.ru

Особо следует выделить фундаментальные труды в области обработки данных ДЗЗ [12, 13], где широко представлены алгоритмы обработки изображений с помощью математических методов. Однако они недостаточно используют возможности современных нейронных сетей для работы с таким материалом. Исследование [14] показало, что сверточные нейронные сети и методы трансферного обучения могут быть эффективно использованы для классификации изображений неба с высокой точностью. В работе [15] авторы продемонстрировали, что рекуррентные нейронные сети (RNN) могут быть эффективно использованы для реконструкции изображений, покрытых облаками, и для классификации земного покрова по временным рядам спутниковых данных. Результаты свидетельствуют о более высокой точности RNN по сравнению с методом случайных лесов, хотя точность моделей на основе временных рядов спектральных характеристик не достигла максимальных значений. Авторы [16] решают задачу восстановления оптических спутниковых изображений, пораженных облаками, с помощью новой системы, основанной на генеративно-состязательных сетях. Предложенная система, названная DC-GAN-CL [16], включает в себя генератор с механизмами кодирования искажений и уточнения признаков, который фокусируется на областях, покрытых облаками, и повышает точность восстановления. Кроме того, в целевые функции системы включены

факторы, обеспечивающие согласованность признаков и пикселей, что позволяет сохранять семантическую связность восстановленных изображений. Однако использование генеративных моделей требует значительных вычислительных ресурсов.

Кроме того, исследователи в области задач ДЗЗ часто решают проблему оценки вегетативности смешанными методами, используя не только компьютерное зрение. Авторы исследования [17] изучали различные методы, включая глубокое обучение и объектно-ориентированный подход, для классификации земного покрова с акцентом на обнаружение хлорофилл-насыщенной растительности, что важно для множества прикладных задач. Они предложили новый объектно-ориентированный метод, использующий карты вегетативности, компьютерное зрение и машинное обучение, и сравнили его производительность с методами глубокого обучения на высокопространственных аэрофотоснимках с RGB и ближним инфракрасным каналами. Предложенный подход показал эффективность по скорости обработки, однако рассматривалась лишь узкая область изображений. Известны работы [18], где оценку вегетативности используют для прогноза урожайности. Основным результатом исследования является обнаружение положительной тенденции в изменении карты вегетативности чая в период вегетации с 2009 по 2018 год в регионе Тануен Лайчуа во Вьетнаме. Авторы показали, что 88,9% территории имеет тренд изменений от -0,001 до 0,001, а 11,1% – от 0,001 до 0,002, со средней скоростью роста 0,00075 в год. Для прогнозирования урожайности чая модель случайного леса показала более высокую точность по сравнению с моделью опорных векторов, при этом ключевыми факторами прогноза оказались средняя температура и нормализованный дифференциальный вегетационный индекс (Normalized Difference Vegetation Index, NDVI) [13]. Тем не менее, одной из важных задач на сегодня остается прогнозирование оценки NDVI со временем.

В настоящей статье рассматривается задача извлечения карт NDVI для прогнозирования данной характеристики с помощью искусственных нейронных сетей. Получаемые прогнозы будут полезны для оценки качества вносимых удобрений на разных участках полей, а также позволят моделировать различные ситуации внесения удобрений, что послужит основой для расчета необходимого количества вносимых удобрений в точечном земледелии. Индекс NDVI может быть интерпретирован, как мера «зелености» участка, а его значения изменяются от -1 до 1. При этом близкие к 1 значения говорят о достаточно хорошей растительности. Но

надо понимать, что при анализе полей, а не лесов, достижение максимальных индексов NDVI маловероятно [13].

Также прогнозирование NDVI может быть полезно при оценке лесных вырубок, заболеваний и старений лесов. В нашей работе анализируются космические снимки полей Краснодарского края, для которых была известна информация о погоде и вносимым удобрением. Важно отметить, что в случае использования аэрокосмической съемки разрешение снимков будет выше, и точность оценки будет еще больше. Кроме того, частота съемки в таком случае тоже может быть выше. Однако в настоящее время обеспечение сельскохозяйственных комплексов беспилотными летательными аппаратами – это только задача будущего. В связи с этим в работе были использованы спутниковые снимки, а в частности – данные с группировкой Copernicus, полученные через API Sentinel-Hub [19].

Целью настоящей работы является разработка моделей для прогнозирования временного ряда вегетационного индекса с использованием данных Sentinel-Hub и сравнение этих моделей по различным мерам качества.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЙ

В первую очередь будет разработана система компьютерного зрения для фильтрации облачных снимков, поскольку это является одной из насущных проблем работы со спутниковыми изображениями. Для обучения необходимо было подготовить датасет от той же спутниковой группировки, для которой планируется будущее извлечение индексов вегетативности. Была выбрана группировка Copernicus и спутники Sentinel-2 за доступность данных и бесплатный доступ к ним. Sentinel-2 – это космические аппараты, используемые для задач зондирования Земли из космоса Европейским космическим агентством. Спутники данной группировки работают в рамках программы мониторинга окружающей среды и безопасности «Copernicus».

Также среди сильных сторон Sentinel-2 необходимо выделить наличие многопиксельной камеры, достаточно малого периода повторной регистрации одного участка земной поверхности, наличие множества частотных каналов.

Всего при загрузке данных через Sentinel-2 можно получать 14 слоев изображений для разных частотных каналов. В эти 14 слоев входят и специализированные внутренние диапазоны. Чтобы рассчитать индекс NDVI необходимо иметь изображение, зарегистрированное всего лишь в двух спектральных диапазонах [13]:

$$NDVI = \frac{NIR - RED}{NIR + RED}, \quad (1)$$

где NIR – результат съемки в ближнем инфракрасном канале (Nearest InfraRed), а RED – результат съемки в красном спектре.

Из (1) следует, что нам требуется только извлечение данных из двух каналов. Пример исходного спутникового снимка в RGB-формате (оптика) и соответствующей ему карты NDVI приведен на рис. 1а. На рис. 1б показана шкала для измерения индекса вегетации.

Таким образом, все слои одного мультиспектрального изображения четко определяются географическими координатами области интереса. Мы также видим, что зеленым травяным участкам на изображении соответствуют высокие значения индекса NDVI. Цвета были получены преобразованием по цветовой карте рис. 1б. На карте NDVI заметно преобладание желтых и оранжевых цветов, которые свидетельствуют о наличии полей (открытой почвы). Индекс выше 0,5 соответствует самым «зеленым» (вегетативным) областям на снимке.

Важно отметить, что индекс NDVI может принимать и отрицательные значения. Обычно они означают снег и лед, а также могут характеризовать здания на карте. Чтобы верно рассчитать NDVI, нужно учитывать множество факторов, такие как дополнительные искажения, влияние атмосферы, геометрическая коррекция. Кроме того, важную роль играет отсутствие облачности на снимках. Облачность приводит к неправильной оценке вегетационного индекса.

В Sentinel-2 уже заложен функционал, который позволяет указать долю облачности на снимке. Однако он не позволяет однозначно идентифицировать каждый пиксель как облако или полезную информацию. Таким образом, он может быть использован как первичный фильтр для подготовки обучающего датасета. К сожалению, такие возможности присутствуют не у всех спутников и не всегда понятно, при каком уровне нужно проводить отбрасывание кадра. Поэтому мы будем обучать более гибкую модель. Чтобы подготовить данные с облачно-

стью и без нее будем использовать пороговые значения.

Выберем интересующий нас участок и передадим его координаты в формате ограничивающего прямоугольника (bounding box) в API Sentinel-Hub. Нам необходимо указать широту и долготу для начальной и конечной точек участка. На следующем шаге мы должны определить временной диапазон, из которого будем выкачивать снимки. В этой работе используются данные с 2016 года и по настоящее время.

В работе предлагается подход для отнесения отдельных пикселов снимка к классу облаков, чтобы не включать их во временной ряд индексов вегетации конкретной области. Для этого используются модели сегментации нейронных сетей, такие как U-Net [20] и SegFormer [21].

Примеры снимков с облаками показаны на рис. 2, а снимков без облаков на рис. 3.

Разметка облачных снимков была выполнена вручную с использованием сервиса Roboflow, а на рис. 4 представлено облачное изображение и его маска.

Из представленного рисунка видно, что благодаря сегментации изображения, можно отбрасывать не снимок целиком, а лишь не учитывать в прогнозе NDVI конкретные пиксели изображения, которые были зашумлены облаками. Альтернативным подходом является применение встроенного фильтра Sentinel-Hub, который позволяет делать селекцию изображений с учетом доли облачных пикселей. Однако он может лишь не включать в выборку для расчета NDVI полные изображения.

Используя API Sentinel-Hub, мы подготовили обучающий датасет. При этом объем выборки для класса «облачно» составил 122 снимка, и 162 снимка для класса «безоблачно». На тестовую выборку было выделено по 37 снимков каждого класса. Для работы со спутниковыми снимками было решено использовать сверточные нейронные сети [22], а также сравнить их с традиционными методами машинного обучения [23].

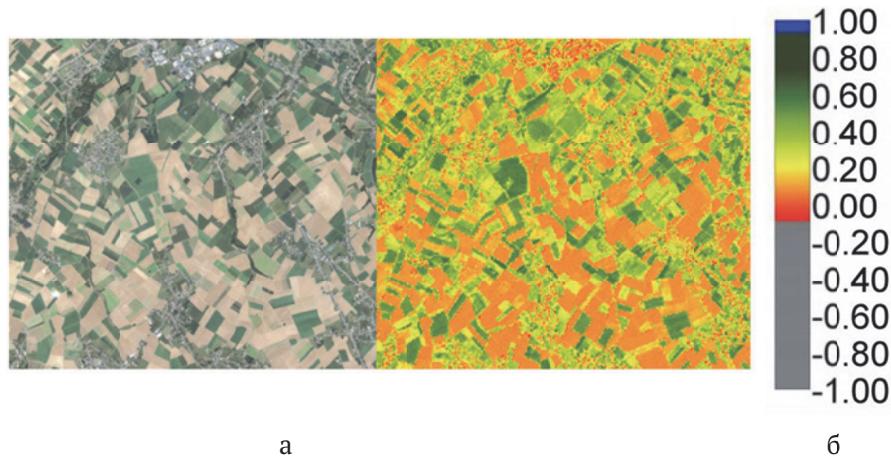


Рис. 1. Исходное спутниковое изображение и его карта NDVI (а)
с соответствующей шкалой значений (б)

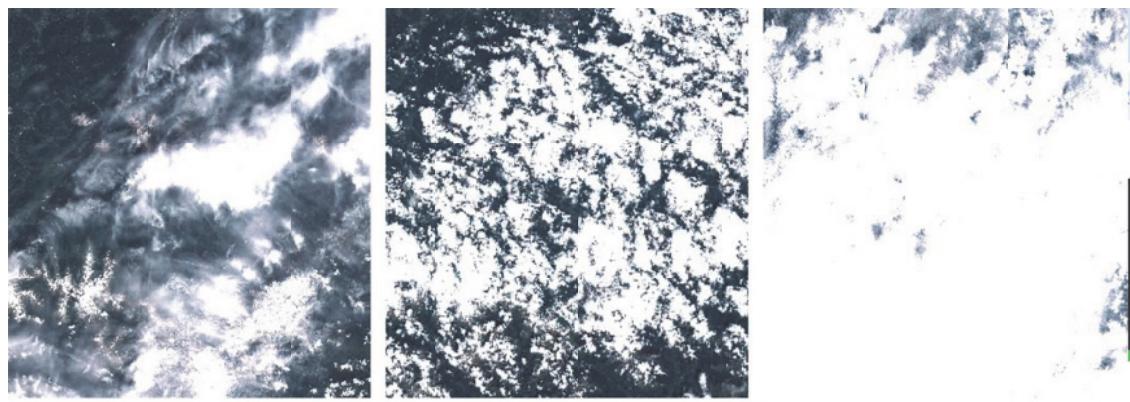


Рис. 2. Изображения класса «облачно»

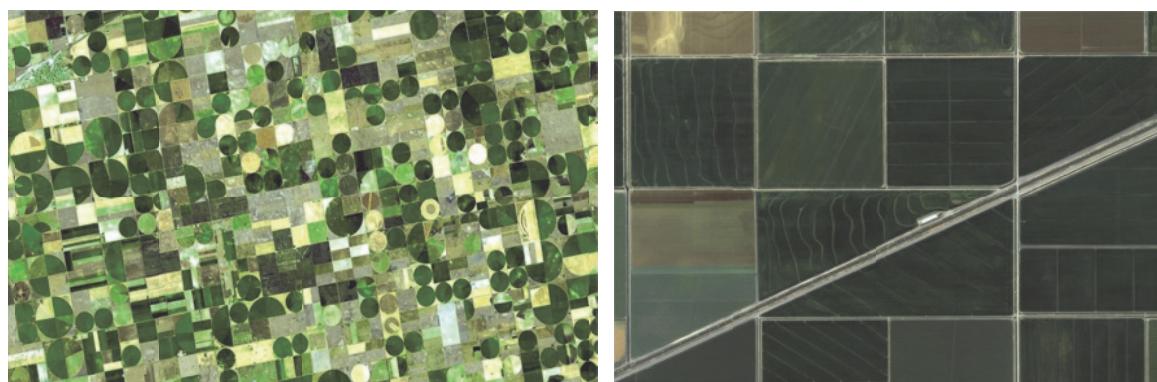


Рис. 3. Изображения класса «безоблачно»

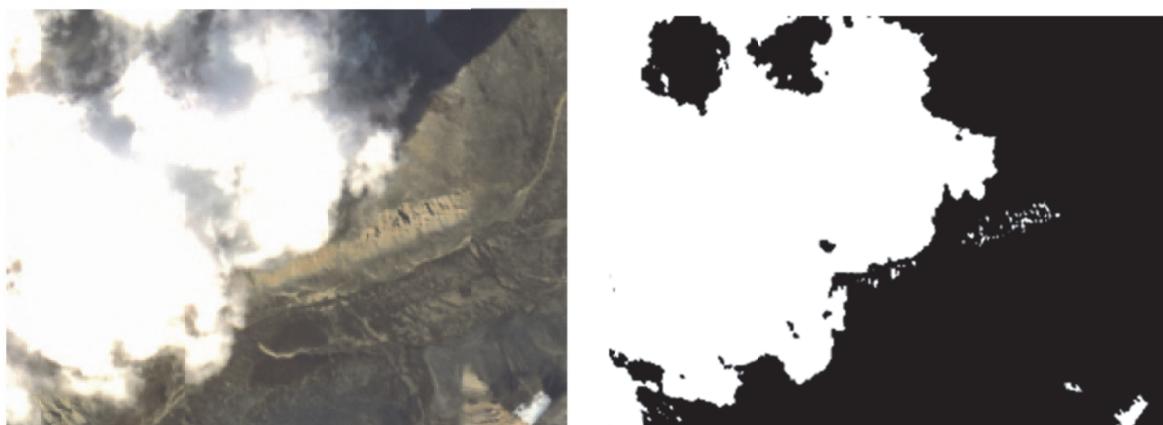


Рис. 4. Исходное изображение и маска облачных пикселей

Альтернативно рассматривался подход с сегментацией изображений. Однако в силу необходимости ручной разметки, объем данных составил 104 изображения на обучающую выборку, 32 – на валидационную и 27 – на тестовую. Основные сравниваемые модели – SegFormer [20], U-Net [21], DeepLabv3+ [24]

Для работы с извлекаемыми временными рядами было предложено использовать рекуррентные нейронные сети, а также ансамблевые модели [25]. Сглаживание временных рядов осуществлялось на основе скользящего среднего. Такой алгоритм может применяться к каждому пикселю в последовательности многозональных

снимков, поэтому будет работать и в случаях с фильтрацией через сегментацию.

На рис. 5 показан пример сглаживания. Например, если брать все снимки, то можно получить такой временной ряд [0,69; 0,64; 0,25; 0,58; 0,25], где значение 0,25 соответствует облачности. Предобработка позволит сразу получить адекватный ряд NDVI [0,69; 0,64; 0,58]. Скользящее среднее с отсеиванием в данном случае зафиксирует окно из трех значений NDVI – [0,64; 0,25; 0,58]. При этом выброс будет учитываться в пересчитанном среднем значении, которое составит 0,49. Это показывает, что для скользящего среднего нужно брать либо

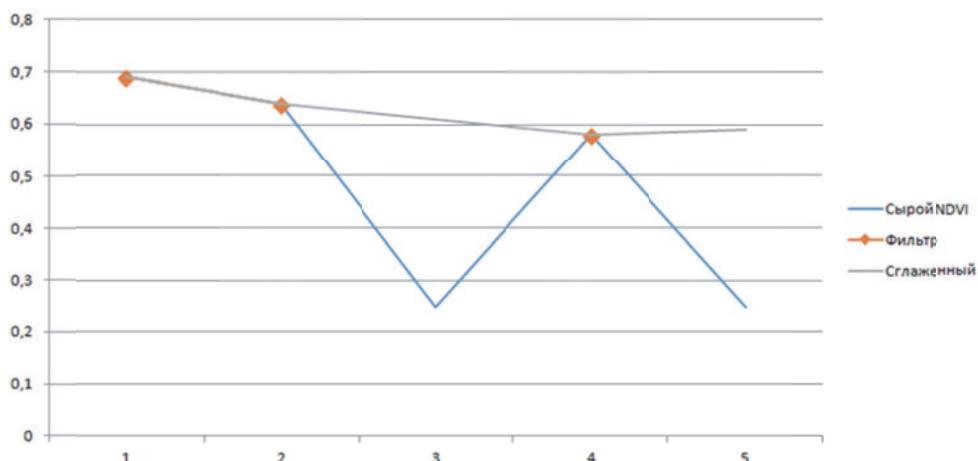


Рис. 5. Сглаживание ряда NDVI

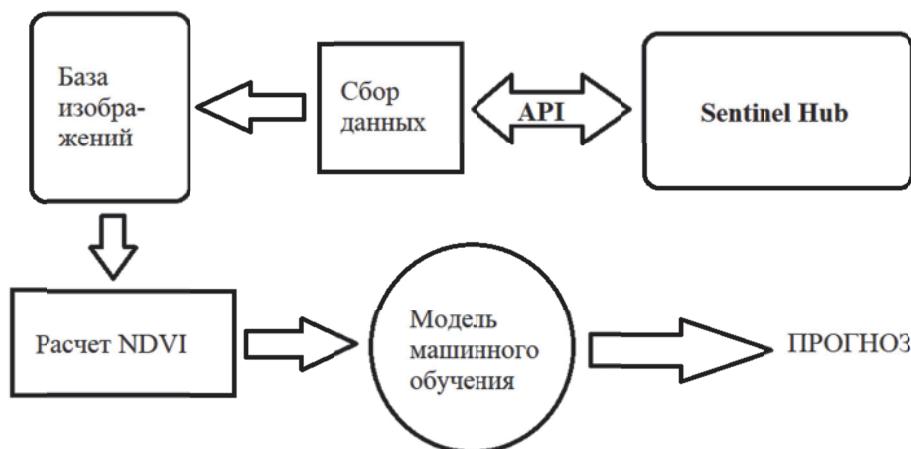


Рис. 6. Блок-схема анализа спутниковых снимков для прогнозирования NDVI

окна большего размера, либо искать другой алгоритм сглаживания, например, с использованием результатов обработки изображений. Отметим, что данные представлены для одного пикселя со всей карты.

После обучения моделей и настройки алгоритмов сглаживания уже идет работа с данными NDVI. Общая схема обработки данных показана на рис. 6.

Такая обработка подразумевает сглаживание сразу в блоке расчет NDVI.

Далее рассмотрим результаты, полученные для классификационных и регрессионных (прогноз NDVI) моделей.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ И ИХ ОБСУЖДЕНИЕ

В тестовой выборке находится всего 74 снимков, при этом датасет сбалансированный. В связи с этим в качестве меры качества была выбрана доля верных распознаваний (Accuracy).

Результаты сравнения различных моделей приведены в табл. 1.

Рассмотрим кратко используемые модели классификации. Модель VGG-19 [26] – глубокая нейронная сеть, разработанная Оксфордской группой визуальной геометрии, состоящая из 19 сверточных слоев. Архитектура ResNet-50 [27] разработана учеными Microsoft и состоит из 50 слоев. Основное отличие от других архитектур заключается в использовании концепции «остаточных связей», благодаря которой частично решается проблема затухающего градиента. Также рассмотрены алгоритмы традиционного машинного обучения: деревья решений [28], ансамбль «случайный лес» [29] и машина опорных векторов [30].

Наилучшее качество распознавания облачных и безоблачных снимков показывает модель VGG-19, исходя из данных табл. 1.

В табл. 2 показаны результаты исследований для сегментационного датасета, а метрикой для сравнения был выбран коэффициент Дайса [31], который может быть рассчитан по формуле:

$$Dice = 2 \frac{|Y \cap \hat{Y}|}{|Y| + |\hat{Y}|}, \quad (2)$$

где Y – множество всех пикселей (маска) за-

Таблица 1. Анализ эффективности классификации

Модель	Accuracy
VGG-19	97,2
ResNet-50	94,4
Случайный лес	87,5
Дерево решений	75,0
Машина опорных векторов	72,2

данного класса в разметке, \hat{Y} – множество всех пикселей (маска) заданного класса в прогнозе, $| \dots |$ – операция вычисления числа пикселей, \cap – операция пересечения множеств.

На рис. 7 показан пример преобразования карт NDVI во временные ряды.

В последующей предобработке следует выполнить разложение временного ряда на сезонные и трендовые составляющие. Также считаются остатки (residuals).

Лучший подход разложения используется из встроенной функции библиотеки statmodels[32]. При этом существует два подхода:

1. Аддитивная модель: $Y[t] = T[t] + S[t] + e[t]$

2. Мультипликативная модель: $Y[t] = T[t] * S[t] * e[t]$

В этих моделях $Y[t]$ – это исходный временной ряд, $T[t]$ – трендовый компонент, $S[t]$ – сезонный компонент, $e[t]$ – остаточный/случайный компонент

Трендовый компонент $T[t]$ оценивается путем применения фильтра свертки к исходным данным. Этот ряд с устраниенным трендом затем используется для оценки сезонного компонента $S[t]$ путем взятия среднего значения для каждого временного периода. Этот более продвинутый метод разложения обеспечивает лучшее разделение базовых компонентов во временном ряде.

Результат такого выделения с помощью мультипликативной модели представлен на рис. 8.

В табл. 3 представлены сравнительные результаты для прогнозирования временных рядов. При этом входные данные представляли из себя 10 предшествующих прогнозируемому значению отсчетов. Общий объем выборки данных об индексе NDVI составил 203 изображения размером 100x100, примерно по 6 на один сезон. Среднее время между снимками до 15 дней, мо-

Таблица 2. Анализ эффективности сегментации

Модель	Dice
SegFormer	73,44
U-Net	69,28
DeepLabv3+	67,14

NDVI

**Рис. 7.** Временной ряд индекса вегетативности на участке, соответствующем одному пикселию карты NDVI

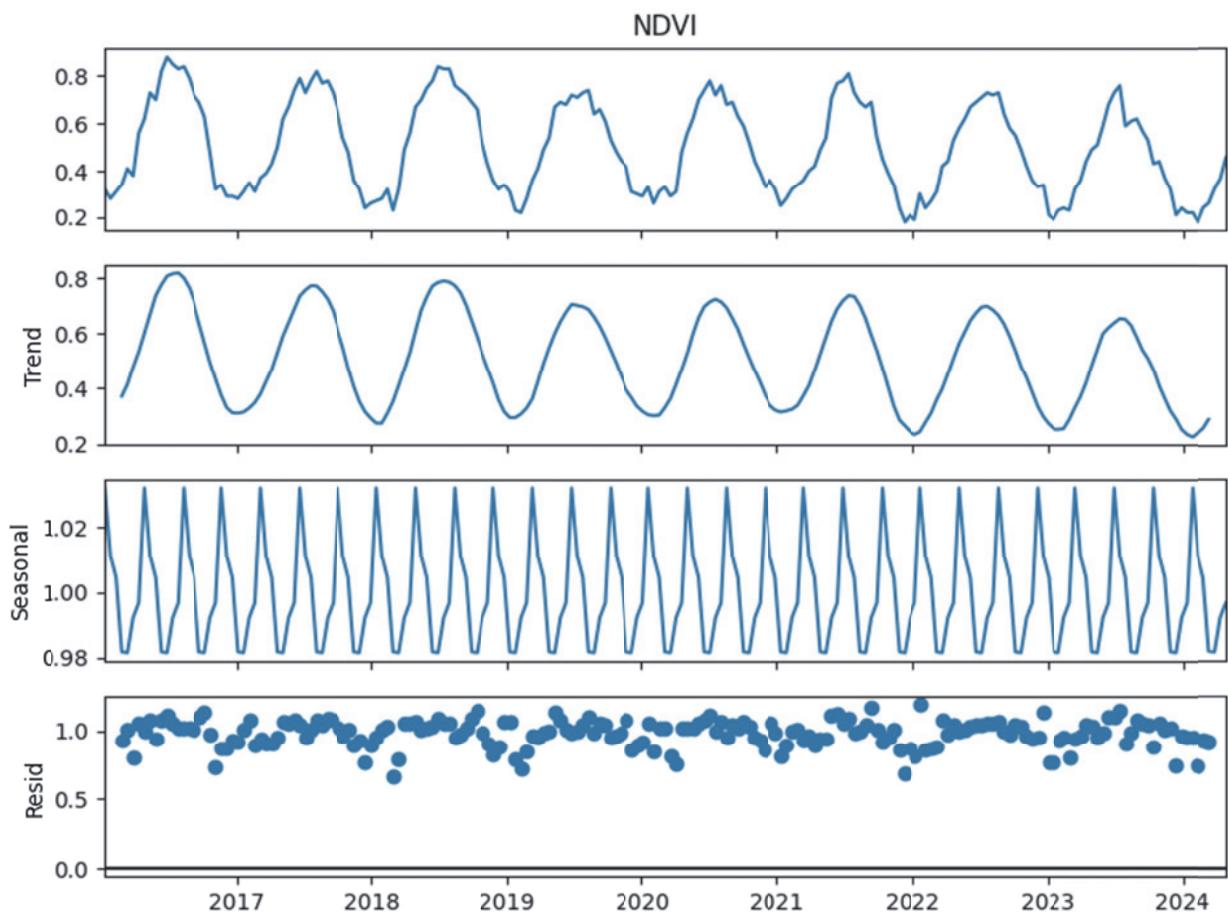


Рис. 8. Декомпозиция индекса вегетативности

Таблица 3. Анализ эффективности прогнозирования

№ п/п	Модель	RMSE	MAPE
1	SARIMA	0,0916	0,2677
2	LSTM	0,0856	0,4084
3	1D CNN	0,1310	0,3650
4	GRU	0,0870	0,3975
5	Ensemble	0,0825	0,2218

дель способна прогнозировать 3 значения вперед, что охватывает диапазон в 1,5 месяца.

Для сравнения были предложены следующие модели:

- SARIMA (Seasonal Autoregressive Integrated Moving Average) – параметрическая статистическая модель временных рядов, расширенная для учета сезонности. Сочетает в себе авторегрессионный (AR), интегрированный (I) и скользящее среднее (MA) компоненты, а также сезонные аналоги этих компонентов [33].

- LSTM (Long Short-Term Memory) – рекуррентная нейронная сеть, способная учитывать долгосрочные зависимости в данных. Имеет специальные «ворота», контролирующие передачу информации между ячейками сети. Хорошо под-

ходит для моделирования временных рядов со сложными нелинейными паттернами [34].

- 1D CNN – разновидность сверточных нейронных сетей, специально разработанная для работы с одномерными последовательностями данных, такими как временные ряды. В отличие от традиционных 2D CNN, которые используются для обработки изображений, 1D CNN применяют сверточные операции вдоль временной оси [35].

- GRU (Gated Recurrent Unit) – рекуррентная нейронная сеть, похожая на LSTM, но с упрощенной структурой. Использует «ворота» для контроля передачи информации между ячейками. Демонстрирует хорошие результаты для моделирования временных рядов, при меньшей вычислительной сложности по сравнению с LSTM [36].

Помимо указанных сетей, реализуется ансамблевая модель, более подробно представленная в [25].

В качестве основной метрики будем использовать корень из среднеквадратичной ошибки (Root Mean Squared Error, RMSE), а также среднюю абсолютную ошибку в процентах (Mean Absolute Percentage Error, MAPE) [37].

Из табл. 3 можно сделать вывод, что наименьшие ошибки совершают ансамблевая модель из рекуррентных сетей. Это обуславливает ее выбор для решения задачи прогнозирования NDVI.

Следует отметить, что в рамках данной работы не учитывались особенности севаоборота и возделываемых сельскохозяйственных культур. Временной ряд NDVI рассматривался как единый агрегированный показатель, без разделения по отдельным сельскохозяйственным угодьям. Включение этого фактора в модели прогнозирования может стать предметом дальнейших исследований.

ЗАКЛЮЧЕНИЕ

Таким образом, в настоящей статье реализован алгоритм фильтрации облачных изображений для последующей оценки карт NDVI. Установлено, что наилучшим фильтром является алгоритм на базе VGG-19. Наилучшие результаты по сегментации облачных пикселей показала модель SegFormer. Далее были обучены модели прогнозирования временных рядов, среди которых лучший результат показали ансамблевые модели нейронных сетей. Они также способны прогнозировать NDVI с учетом дополнительных факторов, таких как погода и вносимые удобрения. В будущем планируется использовать трансформерные модели, как в задаче фильтрации снимков с облаками, так и для решения задачи прогнозирования временных рядов. Также будут собраны данные для моделирования различных ситуаций внесения удобрений и динамики индекса вегетативности.

СПИСОК ЛИТЕРАТУРЫ

1. Аншаков, Г.П. Комплексирование гиперспектральных данных КА «Ресурс-П» для повышения их информативности / Г.П. Аншаков, А.В. Ращупкин, Ю.Н. Журавель // Компьютерная оптика. – 2015. – Т. 39. – №1. – С. 77-82.
2. Хабарова, И.А. Обзор современных достижений в фотограмметрии и аэрофотосъемке / И.А. Хабарова, Д.А. Хабаров, И.Д. Яворская, И.Н. Иванов // Международный журнал прикладных наук и технологий «Integral». – 2019. – Т. 4. – №2. – С. 15-33.
3. Chen, P.-C., Chiang, Y.-C., Weng, P.-Y. Imaging Using Unmanned Aerial Vehicles for Agriculture Land Use Classification. Agriculture 2020, 10, 416. DOI: 10.3390/agriculture10090416.
4. Andriyanov N.A., Vasil'ev K.K., Dement'ev V.E. Investigation of filtering and object detection algorithms for a multizone image sequence // Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2019, XLII-2/W12, pp. 7–10, DOI: 10.5194/isprs-archives-XLII-2-W12-7-2019.
5. Крашенинников, В.Р. Модели случайных полей на поверхностях / В.Р. Крашенинников // Известия Самарского научного центра РАН. – 2012. – № 4(3). – С.812-816.
6. Андриянов, Н.А. Восстановление пространственно неоднородных изображений на базе дважды стохастической модели / Н.А. Андриянов, К.К. Васильев, В.Е. Дементьев, А.В. Белянчиков // Автоматика. – 2022. – Т. 58. – № 5. – С. 43-50.
7. Андриянов, Н.А. Цифровая обработка и моделирование авторегрессионных и дважды стохастических случайных полей / Н.А. Андриянов, К.К. Васильев, В.Е. Дементьев // Свидетельство о регистрации программы для ЭВМ RU 2016616596, 15.06.2016. Заявка № 2016614011 от 19.04.2016.
8. Крашенинников, В.Р. Синтез волновой модели многомерного случайного поля с заданной корреляционной функцией / В.Р. Крашенинников, Р.Р. Микеев, В.В. Тишкин // Известия Самарского научного центра Российской академии наук. – 2014. – Т. 16. – № 6-2. – С. 474-478.
9. Андриянов, Н.А. Оценивание координат объектов с использованием сверточных сетей и карт глубины / Н.А. Андриянов // В сборнике: Информационные технологии и нанотехнологии (ИТНТ-2022). Сборник трудов по материалам VIII Международной конференции и молодежной школы. В 5-ти томах [под редакцией А.В. Никонорова]. – Самара, 2022. – С. 41972.
10. Andriyanov N.A., Dementiev V.E., Tashlinskiy A.G. Development of a productive transport detection system using convolutional neural networks// Pattern Recognition and Image Analysis. Advances in Mathematical Theory and Applications. 2022. T. 32. № 3. С. 495-500.
11. Tehsin S., Kausar S., Jameel A., Humayun M., Almofarreh D.K. Satellite Image Categorization Using Scalable Deep Learning // Applied Sciences 2023, vol. 13, id 5108. DOI: 10.3390/app13085108.
12. Рис, У.Г. Основы дистанционного зондирования / У.Г. Рис // М.: Техносфера, 2006. – 346 с.
13. Шовенгердт, Р. А. Дистанционное зондирование. Модели и методы обработки изображений / Р.А. Шовенгердт, А.В. Кирюшин, А.И. Демьянников [пер. с англ.]. – 3-е изд. – М.: Техносфера, 2013. – 589 с.
14. Hernández-López R., Travieso-González C.M., Ajali-Hernández N.I. Sky Image Classification Based on Transfer Learning Approaches // Sensors 2024, vol. 24, id 3726. DOI: 10.3390/s24123726.
15. Alonso-Sarria F., Valdiveiso-Ros C., Gomariz-Castillo F. Imagery Time Series Cloud Removal and Classification Using Long Short Term Memory Neural Networks // Remote Sens. 2024, vol. 16, id 2150. DOI: 10.3390/rs16122150.
16. Zhou J., Luo X., Rong W., Xu H. Cloud Removal for Optical Remote Sensing Imagery Using Distortion Coding Network Combined with Compound Loss Functions // Remote Sens. 2022, vol. 14, id 3452. DOI: 10.3390/rs14143452.
17. Ayhan B., Kwan C., Budavari B., Kwan L., Lu Y., Perez D., Li J., Skarlatos D., Vlachos M. Vegetation Detection

- Using Deep Learning and Conventional Methods // Remote Sens. 2020, vol. 12, id 2502. DOI: 10.3390/rs12152502.
18. Phan P., Chen N., Xu L., Dao D.M., Dang D. NDVI Variation and Yield Prediction in Growing Season: A Case Study with Tea in Tanuyen Vietnam // Atmosphere 2021, vol. 12, id 962. DOI: 10.3390/atmos12080962.
 19. Источник данных Sentinel. URL: <https://www.sentinel-hub.com/> (дата обращения 25.04.2024).
 20. Singh N.J., Nongmeikapam K. Semantic Segmentation of Satellite Images Using Deep-Unet // Arab J Sci Eng. 2023, vol. 48, pp. 1193–1205. DOI: 10.1007/s13369-022-06734-4.
 21. Андриянов, Н.А. Мониторинг состояния металлических изделий на основе систем компьютерного зрения / Н.А. Андриянов, А.А. Волненко, В.Е. Дементьев // Нейрокомпьютеры: разработка, применение. – 2023. – Т. 25. – № 5. – С. 50-57. DOI: <https://doi.org/10.18127/j19998554-202305-07>.
 22. Andriyanov N., Papakostas G. Optimization and Benchmarking of Convolutional Networks with Quantization and OpenVINO in Baggage Image Recognition // 2022 VIII International Conference on Information Technology and Nanotechnology (ITNT), Samara, Russian Federation, 2022, pp. 1-4, DOI: 10.1109/ITNT55410.2022.9848757.
 23. Liu W., Zhang J., Zhao Y. A Comparison of Deep Learning and Traditional Machine Learning Approaches in Detecting Cognitive Impairment Using MRI Scans // 2022 IEEE 46th Annual Computers, Software, and Applications Conference (COMPSAC), Los Alamitos, CA, USA, 2022, pp. 998-1001, DOI: 10.1109/COMPSAC54236.2022.00154.
 24. Hsu, C.-Y., Hu, R., Xiang, Y.; Long, X., Li, Z. Improving the DeepLabv3+ Model with Attention Mechanisms Applied to Eye Detection and Segmentation. Mathematics 2022, 10, 2597. <https://doi.org/10.3390/math10152597>.
 25. Библиотека TSensemle. – URL: <https://github.com/saschakrs/TSensemle> (дата обращения: 12.05.2024).
 26. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition // arXiv preprints, 2014. URL: <https://arxiv.org/abs/1409.1556> (дата обращения: 16.05.2024).
 27. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // arXiv preprints, 2015. URL: <https://arxiv.org/abs/1512.03385>. (дата обращения: 16.05.2024).
 28. Некрасов, М.В. Автоматизация метода «Дерево решений» / М.В. Некрасов // Актуальные вопросы экономических наук. – № 32, – 2013. – С. 66-70.
 29. Ho T.K. Random decision forests // In Proceedings of 3rd international conference on document analysis and recognition, vol. 1, 1995, pp. 278–282.
 30. Cortes C., Vapnik, V. Support-vector networks // Machine Learning, 20(3), 1995, pp. 273–297.
 31. Egorov A.A. Lysenkova S.A., Mazayshvili K.V. Convolutional networks for segmentation of large vein images // Vestnik KRAUNC. Fiz.-Mat. Nauki, 2020, vol. 31(2), pp. 117–128
 32. Statmodels. – URL: https://www.statsmodels.org/dev/generated/statsmodels.tsa.seasonal.seasonal_decompose.html (дата обращения: 16.05.2024).
 33. Permanasari A. E., Hidayah I. and Bustoni I. A. SARIMA (Seasonal ARIMA) implementation on time series to forecast the number of Malaria incidence // 2013 International Conference on Information Technology and Electrical Engineering (ICITEE), Yogyakarta, Indonesia, 2013, pp. 203-207, doi: 10.1109/ICITEED.2013.6676239.
 34. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation, 1997, vol. 9(8), pp. 1735–1780.
 35. Kiranyaz S., Ince T., Abdeljaber O., Avci O. and Gabbouj M. 1-D Convolutional Neural Networks for Signal Processing Applications // ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Brighton, UK, 2019, pp. 8360-8364, doi: 10.1109/ICASSP.2019.8682194.
 36. Li X., Ma X., Xiao F., Wang F., Zhang S. Application of Gated Recurrent Unit (GRU) Neural Network for Smart Batch Production Prediction // Energies 2020, 13, 6121. <https://doi.org/10.3390/en13226121>
 37. Андриянов, Н.А. Построение и оценка моделей машинного обучения. 01.04.02 «Прикладная математика и информатика», всех профилей (программы подготовки магистров) : учебное пособие / Н. А. Андриянов, П. В. Никитин. – М.: Финансовый университет, 2023. – 140 с. – Текст : электронный // Лань : электронно-библиотечная система. – URL: <https://e.lanbook.com/book/345374> (дата обращения: 16.09.2024).

FORECASTING VEGETATION INDICES USING SATELLITE IMAGES

© 2024 N.A. Andriyanov

Financial University under the Government of the Russian Federation, Moscow, Russia

This paper presents a solution to the problem of vegetativity prediction based on time series models. At the same time, special attention is paid to the development of a filter of images with increased cloudiness. The classification accuracy of distorted images at above 95% based on convolutional neural networks is obtained. The NDVI prediction error using an ensemble of neural networks is less than 0.1. It is shown how the developed algorithms can be used for differential fertilizer application. Expressions for calculating NDVI and techniques for smoothing indices in case of missing data and filtering cloud images are presented. The results obtained in this paper can be useful for specialists engaged in processing remote sensing data from space, and the algorithms for filtering cloud images can be used in solving other applied problems, such as fire monitoring.

Keywords: neural networks, aerospace imagery, satellite monitoring, vegetativity index, image processing.

DOI: 10.37313/1990-5378-2024-26-4(3)-329-339

EDN: KMEBGQ

REFERENCES

1. Anshakov, G.P. Kompleksirovaniye giperspektral'nyh dannyh KA «Resurs-P» dlya povysheniya ih informativnosti / G.P. Anshakov, A.V. Rashchupkin, YU.N. Zhuravel' // Komp'yuternaya optika. – 2015. – T. 39. – №1. – S. 77-82.
2. Habarova, I.A. Obzor sovremennoy dostizheniy v fotogrammetrii i aerofotosemke / I.A. Habarova, D.A. Habarov, I.D. Yavorskaya, I.N. Ivanov // Mezhdunarodnyj zhurnal prikladnyh nauk i tekhnologij «Integral». – 2019. – T. 4. – №2. – S. 15-33.
3. Chen, P.-C., Chiang, Y.-C., Weng, P.-Y. Imaging Using Unmanned Aerial Vehicles for Agriculture Land Use Classification. Agriculture 2020, 10, 416. DOI: 10.3390/agriculture10090416.
4. Andriyanov N.A., Vasil'ev K.K., Dement'ev V.E. Investigation of filtering and object detection algorithms for a multizone image sequence // Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2019, XLII-2/W12, pp. 7-10, DOI: 10.5194/isprs-archives-XLII-2-W12-7-2019.
5. Krasheninnikov, V.R. Modeli sluchajnyh polej na poverhnostyah / V.R. Krasheninnikov // Izvestiya Samarskogo nauchnogo centra RAN. – 2012. – № 4(3). – S.812-816.
6. Andriyanov, N.A. Vosstanovlenie prostranstvenno neodnorodnyh izobrazhenij na baze dvazhdy stohasticheskoy modeli / N.A. Andriyanov, K.K. Vasil'ev, V.E. Dement'ev, A.V. Belyanchikov // Avtometriya. – 2022. – T. 58. – № 5. – S. 43-50.
7. Andriyanov, N.A. Cifrovaya obrabotka i modelirovaniye avtoregressionnyh i dvazhdy stohasticheskikh sluchajnyh polej / N.A. Andriyanov, K.K. Vasil'ev, V.E. Dement'ev // Svidetel'stvo o registraciye programmy dlya EVM RU 2016616596, 15.06.2016. Zayavka № 2016614011 ot 19.04.2016.
8. Krasheninnikov, V.R. Sintez volnovoj modeli mnogomernogo sluchajnogo polya s zadannoj korrelyacionnoj funkciyej / V.R. Krasheninnikov, R.R. Mikeev, V.V. Tishkin // Izvestiya Samarskogo nauchnogo centra Rossiijskoj akademii nauk. – 2014. – T. 16. – №6-2. – S. 474-478.
9. Andriyanov, N.A. Ocenivaniye koordinat ob'ektov s ispol'zovaniem svertochnyyh setej i kart glubiny / N.A. Andriyanov // V sbornike: Informacionnye tekhnologii i nanotekhnologii (ITNT-2022). Sbornik trudov po materialam VIII Mezhdunarodnoy konferencii i molodezhnoy shkoly. V 5-ti tomah [pod redakcijej A.V. Nikonorova]. – Samara, 2022. – S. 41972.
10. Andriyanov N.A., Dementiev V.E., Tashlinskiy A.G. Development of a productive transport detection system using convolutional neural networks // Pattern Recognition and Image Analysis. Advances in Mathematical Theory and Applications. 2022. T. 32. № 3. S. 495-500.
11. Tehsin S., Kausar S., Jameel A., Humayun M., Almofarreh D.K. Satellite Image Categorization Using Scalable Deep Learning // Applied Sciences 2023, vol. 13, id 5108. DOI: 10.3390/app13085108.
12. Ris, U.G. Osnovy distancionnogo zondirovaniya / U.G. Ris // M.: Tekhnosfera, 2006. – 346 s.
13. Shovengerdt, R.A. Distancionnoe zondirovanie. Modeli i metody obrabotki izobrazhenij / R.A. Shovengerdt, A.V. Kiryushin, A.I. Dem'yanikov [per. s angl.]. – 3-e izd. – M.: Tekhnosfera, 2013. – 589 s.
14. Hernández-López R., Travieso-González C.M., Ajali-Hernández N.I. Sky Image Classification Based on Transfer Learning Approaches // Sensors 2024, vol. 24, id 3726. DOI: 10.3390/s24123726.
15. Alonso-Sarria F., Valdivieso-Ros C., Gomariz-Castillo F. Imagery Time Series Cloud Removal and Classification Using Long Short Term Memory Neural Networks // Remote Sens. 2024, vol. 16, id 2150. DOI: 10.3390/rs16122150.
16. Zhou J., Luo X., Rong W., Xu H. Cloud Removal for Optical Remote Sensing Imagery Using Distortion Coding Network Combined with Compound Loss Functions // Remote Sens. 2022, vol. 14, id 3452. DOI: 10.3390/rs14143452.
17. Ayhan B., Kwan C., Budavari B., Kwan L., Lu Y., Perez D., Li J., Skarlatos D., Vlachos M. Vegetation Detection Using Deep Learning and Conventional Methods // Remote Sens. 2020, vol. 12, id 2502. DOI: 10.3390/rs12152502.
18. Phan P., Chen N., Xu L., Dao D.M., Dang D. NDVI Variation and Yield Prediction in Growing Season: A Case Study with Tea in Tanuyen Vietnam // Atmosphere 2021, vol. 12, id 962. DOI: 10.3390/atmos12080962.
19. Istochnik dannyh Sentinel. URL: <https://www.sentinel-hub.com/> (data obrashcheniya 25.04.2024).
20. Singh N.J., Nongmeikapam K. Semantic Segmentation of Satellite Images Using Deep-Unet // Arab J Sci Eng. 2023, vol. 48, pp. 1193-1205. DOI: 10.1007/s13369-022-06734-4.
21. Andriyanov, N.A. Monitoring sostoyaniya metallicheskikh izdelij na osnove sistem komp'yuternogo zreniya / N.A. Andriyanov, A.A. Volnenko, V.E. Dement'ev // Nejrokomp'yutery: razrabotka, primenie. – 2023. – T. 25. – № 5. – S. 50-57. DOI: <https://doi.org/10.18127/j19998554-202305-07>.
22. Andriyanov N., Papakostas G. Optimization and Benchmarking of Convolutional Networks with Quantization and OpenVINO in Baggage Image Recognition // 2022 VIII International Conference on Information Technology and Nanotechnology (ITNT), Samara, Russian Federation, 2022, pp. 1-4, DOI: 10.1109/ITNT55410.2022.9848757.
23. Liu W., Zhang J., Zhao Y. A Comparison of Deep Learning and Traditional Machine Learning Approaches in Detecting Cognitive Impairment Using MRI Scans // 2022 IEEE 46th Annual Computers, Software, and Applications Conference (COMPSAC), Los Alamitos, CA, USA, 2022, pp. 998-1001, DOI: 10.1109/COMPSAC54236.2022.00154.
24. Hsu, C.-Y., Hu, R., Xiang, Y., Long, X., Li, Z. Improving the Deeplabv3+ Model with Attention Mechanisms Applied to Eye Detection and Segmentation. Mathematics 2022, 10, 2597. <https://doi.org/10.3390/math10152597>.
25. Biblioteka TSensemle. – URL: <https://github.com/saschakrs/TSensemle> (data obrashcheniya: 12.05.2024).
26. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition // arXiv preprints, 2014. URL: <https://arxiv.org/abs/1409.1556> (data obrashcheniya: 16.05.2024).
27. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // arXiv preprints,

2015. URL: <https://arxiv.org/abs/1512.03385>. (data obrashcheniya: 16.05.2024).
28. Nekrasov, M.V. Avtomatizaciya metoda «Derevo reshenij» / M.V. Nekrasov // Aktual'nye voprosy ekonomicheskikh nauk. – № 32, – 2013. – С. 66-70.
29. Ho T. K. Random decision forests // In Proceedings of 3rd international conference on document analysis and recognition, vol. 1, 1995, pp. 278–282.
30. Cortes C., Vapnik, V. Support-vector networks // Machine Learning, 20(3), 1995, pp. 273–297.
31. Egorov A.A., Lysenkova S.A., Mazayshvili K.V. Convolutional networks for segmentation of large vein images // Vestnik KRAUNC. Fiz.-Mat. Nauki, 2020, vol. 31(2), pp. 117–128
32. Statmodels. – URL: https://www.statsmodels.org/dev/generated/statsmodels.tsa.seasonal.seasonal_decompose.html (data obrashcheniya: 16.05.2024).
33. Permanasari A.E., Hidayah I. and Bustoni I.A. SARIMA (Seasonal ARIMA) implementation on time series to forecast the number of Malaria incidence // 2013 International Conference on Information Technology and Electrical Engineering (ICITEE), Yogyakarta, Indonesia, 2013, pp. 203-207, doi: 10.1109/ICITEED.2013.6676239.
34. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation, 1997, vol. 9(8), pp. 1735–1780.
35. Kiranyaz S., Ince T., Abdeljaber O., Avci O. and Gabbouj M. 1-D Convolutional Neural Networks for Signal Processing Applications // ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Brighton, UK, 2019, pp. 8360-8364, doi: 10.1109/ICASSP.2019.8682194.
36. Li X., Ma X., Xiao F., Wang F., Zhang S. Application of Gated Recurrent Unit (GRU) Neural Network for Smart Batch Production Prediction // Energies 2020, 13, 6121. <https://doi.org/10.3390/en13226121>
37. Andriyanov, N.A. Postroenie i ocenka modeley mashinnogo obucheniya. 01.04.02 «Prikladnaya matematika i informatika», vsekh profilej (programmy podgotovki magistrov) : uchebnoe posobie / N. A. Andriyanov, P. V. Nikitin. – M. : Finansovyj universitet, 2023. – 140 s. – Tekst : elektronnyj // Lan : elektronno-bibliotechnaya sistema. – URL: <https://e.lanbook.com/book/345374> (data obrashcheniya: 16.09.2024).