

Н. С. Хохлов, О. И. Бокова, С. В. Канавин, И. В. Гилев, Р. В. Ртищев

РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОГО ПРОГРАММНОГО МОДУЛЯ НА ОСНОВЕ АППАРАТА НЕЙРОННЫХ СЕТЕЙ ДЛЯ ВИЗУАЛИЗАЦИИ И АВТОМАТИЧЕСКОГО АНАЛИЗА ХАРАКТЕРИСТИК СПЕКТРОВ ИНФОРМАЦИОННОГО СИГНАЛА И ДЕСТРУКТИВНЫХ ВОЗДЕЙСТВИЙ

Аннотация. Предложен способ реализации интеллектуального программного модуля на основе аппарата нейронных сетей для визуализации и автоматического анализа характеристик спектров информационного сигнала и деструктивных воздействий. Приведена процедура выбора и создания модели машинного обучения, позволяющей выявлять наличие деструктивного воздействия и его признаков. Обучение модели нейронной сети происходит в облачной среде с использованием графического процессора. Для обучения модели нейронной сети использована специализированная библиотека. Обучение реализуется на параметрах нейронной сети, характеризующих количество прохода датасета через нейронную сеть в прямом и обратном направлении. В результате обучения получены графики, характеризующие зависимости ошибок от количества эпох обучения моделей. Разработаны алгоритм выделения характеристик мощности, ширины спектра деструктивного воздействия в спектре информационного сигнала и интеллектуальный программный модуль (скрипт) для их автоматического анализа. Механизм анализа ширины спектра и мощности деструктивного воздействия в спектре информационного сигнала включает в себя программное обеспечение и модели машинного обучения для распознавания текста на изображениях.

Ключевые слова: интеллектуальный программный модуль, нейронные сети, автоматический анализ характеристик спектров, деструктивные воздействия, модель машинного обучения, алгоритм автоматического анализа характеристик спектра информационного сигнала.

Для цитирования: Разработка интеллектуального программного модуля на основе аппарата нейронных сетей для визуализации и автоматического анализа характеристик спектров информационного сигнала и деструктивных воздействий / Н. С. Хохлов, О. И. Бокова, С. В. Канавин [и др.] // Вестник Ростовского государственного университета путей сообщения. – 2024. – № 1. – С. 158–168. – DOI 10.46973/0201-727X_2024_1_158.

Введение

На сегодняшний день применение систем беспроводной связи является эффективным инструментом для обеспечения эффективной деятельности сотрудников различных ведомств, в том числе для систем железнодорожной автоматизации, систем радиосвязи [1]. Такие системы могут быть подвержены различного рода угрозам, возникающим вследствие деструктивных воздействий. Деструктивное воздействие может приводить к разрушению информации, циркулирующей в системах связи. Разрушение передаваемой информации может быть реализовано за счет ее уничтожения, искажения, блокирования. Под уничтожением информации будем понимать такое деструктивное воздействие на информационный поток данных, циркулирующих в СС СН, при котором уровень вероятности показателя битовых ошибок bit error rate (BER) превосходит максимально допустимое значение данного показателя, определенного для конкретной системы связи, результатом которого является отсутствие возможности восстановления данных. Искажение информации является результатом деструктивного воздействия на пакеты информации, а также перехвата, внесения изменений и внедрения умышленно искаженных информационных пакетов, приводящего к неправильному декодированию информации на приемной стороне. Блокирование информации подразумевает генерацию деструктивных воздействий большей мощности по сравнению с информационным сигналом, а также внедрение ложных пакетов, осуществляющих блокирование информационного обмена в СС СН [2]. Указанные виды воздействий могут дестабилизировать работу систем железнодорожной радиосвязи и нарушить обмен информацией между диспетчером и подвижным составом. Одним из возможных путей решения данной проблемы может являться автоматизация мониторинга спектров информационных

сигналов и своевременное обнаружение деструктивных воздействий с использованием технологии искусственного интеллекта.

Нейронные сети являются важным инструментом в современном мире и способны успешно решать самые разные задачи. Аппарат нейронных сетей применяется в области анализа алгоритмов поиска объектов на изображениях [3, 4], анализа методов детектирования объектов на радиолокационных изображениях [5], анализа мультиспектральных изображений [6], анализа сетевого трафика [7], биометрической аутентификации на основе нечеткого образа личности пользователя [8]. В научных исследованиях рассматриваются примеры применения нейронных сетей для обнаружения аномалий, нештатных состояний и деструктивных воздействий на информационные системы различного назначения. В монографиях [9, 10] В. В. Фисуна, С. М. Климова, М. П. Сычева, А. В. Астрахова рассматриваются методы и модели обнаружения и предотвращения компьютерных атак с помощью аппарата нечеткой логики и нейронных сетей. В работе О. И. Шелухина [11] рассматриваются вопросы диагностики и защиты сетевых ресурсов от аномальных воздействий, приводящих к уничтожению, искажению и блокированию информации с использованием методов машинного обучения и анализа темпоральных данных, включая информационные сигналы. На основе проведенного анализа научных работ можно сделать вывод об актуальности данного направления научных исследований и возможности применения аппарата нейронных сетей в задачах обнаружения деструктивных воздействий в системах беспроводной связи.

Целью работы является разработка программного модуля для автоматизации анализа характеристик спектров информационного сигнала и деструктивных воздействий на основе аппарата нейронных сетей.

Далее в статье рассмотрим общие сведения о нейронных сетях, их видах, характеристиках и классификации, а также варианты применения нейронных сетей.

Искусственный нейрон как основа нейронных сетей

Искусственный нейрон можно сравнить с биологическим нейроном, который представляет из себя нервную клетку, состоящую из тела, дендритов и аксона. От тела отходит множество коротких и толстых отростков, называемых дендритами. Они принимают импульсы с тех нейронов, которые находятся в сети раньше, чем этот нейрон. От тела отходит также один очень длинный и тонкий отросток, называемый аксоном. Это выходной отросток – по нему нейрон передает электрохимический импульс следующим нейронам в сети. Окончание аксона имеет разветвления, через которые выходной сигнал может быть передан нескольким следующим нейронам. Таким образом, через множество дендритов нейрон получает входные сигналы, в теле нейрона они обрабатываются, а через единственный аксон выходной импульс от нейрона передается дальше. Нейрон, помимо обработки сигнала, вынужден еще выполнять множество других функций, поддерживающих его жизнь [12].

Искусственный нейрон принимает входные данные (x_1, x_2, \dots, x_n) , после чего выполняет некоторые операции, а затем выводит результат y . В теле искусственного нейрона имеется сумматор, где каждый входной сигнал умножается на некоторый действительный весовой коэффициент, в результате чего формируется итоговая сумма. В упрощенном виде эту математическую модель можно рассмотреть в виде нейрона, в том числе искусственного, имеющего какие-то входы, через которые он принимает сигнал – x . Для входных сигналов вводится понятие весов – w , на которые умножаются эти сигналы. Веса используются для вычисления выходных значений нейрона на основе входных значений. Они могут меняться во время обучения нейронной сети, когда алгоритм оптимизации изменяет их так, чтобы минимизировать ошибку сети на обучающем наборе данных. В теле искусственного нейрона поступившие на входы сигналы умножаются на их веса. Сигнал первого входа x умножается на соответствующий этому входу вес, сигнал x_2 – на w_2 , и так до последнего w -го входа. Затем в сумматоре эти произведения суммируются. В итоге получаем сумму произведений значений входных сигналов z на их веса, вычисляемую по (1).

$$z = x_1 w_1 + x_2 w_2 + x_3 w_3 + \dots + x_n w_n. \quad (1)$$

Полученное значение передается в функцию активации. Функция активации обрабатывает данное значение и выдает выходной сигнал y . В этом заключается схожесть биологического и искусственного нейрона. Однако, в отличие от биологического нейрона, искусственный нейрон не выполняет другие функции, необходимые для поддержания его жизни. Искусственный нейрон с входами и выходным значением представлен на рис. 1.




Рис. 1. Схема искусственного нейрона

Основные архитектуры нейронных сетей

В нейронных сетях можно выделить три основные архитектуры

- 1 Сверточные нейросети (Convolutional Neural Network – далее CNN).
- 2 Рекуррентные нейросети (Recurrent Neural Network – далее RNN).
- 3 Нейросети прямого распространения (Feed Forward Neural Network – далее FNN).

Рассмотрим варианты их применения.

CNN используются для задач компьютерного зрения, таких как классификация изображений, детектирование объектов и распознавание лиц. Она является типом глубокой нейронной сети, специально разработанной для анализа изображений, которая состоит из нескольких слоев, включая сверточные слои, пулинговые слои и полносвязные слои. Сверточные слои в CNN выполняют операцию свертки, которая позволяет извлекать локальные признаки из изображений. Они применяют фильтры к входному изображению для обнаружения различных признаков, таких как границы, текстуры и формы. Затем пулинговые слои уменьшают размерность изображения, сохраняя важные признаки. После этого полносвязные слои используют эти признаки для классификации или регрессии. CNN имеют несколько преимуществ по сравнению с другими моделями машинного обучения для анализа фотографий.

RNN нашли себе применение в синтезе и распознавании речи, машинном переводе [12]. Это тип нейронной сети, в которой выходные данные предыдущего шага подаются в качестве входных данных для текущего шага. В традиционных нейронных сетях все входы и выходы независимы друг от друга, но в случаях, когда нужно предсказать следующее слово предложения, требуются предыдущие слова и, следовательно, возникает необходимость запомнить предыдущие слова. RNN решает данную проблему с помощью скрытого слоя. Основной и наиболее важной особенностью RNN является ее скрытое состояние, которое запоминает некоторую информацию о последовательности.

FNN используются для решения задач анализа данных, автоматического распознавания, прогнозирования и принятия решений на основе данных. Такие сети работают в одном направлении – они передают информацию от входа к выходу. В FNN все нейроны собираются по слоям, которые состоят из входных, скрытых и выходных клеток. В пределах одного слоя нейроны не связаны между собой, но соседние слои полностью связаны.

Обучение нейронных сетей

Алгоритмы обучения нейронных сетей можно разделить на два больших класса: с учителем и без учителя.

Обучение с учителем означает, что сеть принимает значения как входных, так и некоторых выходных значений. В самом начале требуется разметить входные значения, для которых известны результаты. На процессе обучения нейросеть делает предсказания на основе весов, затем их сравнивает с известным результатом. Если предсказание нейросети не совпадает с ожидаемым результатом, то происходит процесс, называемый обратным распространением ошибки. В ходе него вычисляется, насколько каждый вес внутри нейросети способствовал общей ошибке. Затем эти веса корректируются в направлении, которое уменьшит ошибку [13]. Далее происходит процесс повторения до тех пор, пока ошибки предсказания ожидаемого результата будут минимальными. Последним этапом является тестирование нейронной сети на новых данных.

При обучении без учителя нейронная сеть самостоятельно формирует выходы. В отличие от обучения с учителем, в подготовке данных не требуется их разметка. Нейросеть сама классифицирует входные данные. Это может быть кластеризация (группировка похожих объектов), поиск аномалий (выявление объектов, которые отличаются от большинства) [13].

Применение нейронных сетей

Деструктивные воздействия снижают качество радиосвязи и усложняют передачу информации за счет ее уничтожения, искажения или блокирования. Для их анализа могут использоваться приборы типа анализатора спектра [14]. Анализатор спектра – это прибор, который позволяет измерять и анализировать спектральные характеристики сигнала. Он может обнаруживать наличие и интенсивность различных спектральных составляющих информационного сигнала, что в итоге позволяет выявить деструктивное воздействие и провести его анализ. Для детектирования объектов, полученных при использовании анализатора спектра, на изображении наилучшим образом подходит сеть структуры CNN. Эффективным алгоритмом обнаружения объектов на базе сверточной нейронной сети является YOLO. Это быстрый одноэтапный метод обнаружения объектов, включающий входной сегмент, магистраль, шею и выходной сегмент [15].

Входной сегмент выполняет увеличение данных мозаики, адаптивный расчет привязки и адаптивное заполнение оттенков серого на входном изображении. Магистральная сеть и шейный модуль образуют центральные структуры сети YOLOv8.

Входное изображение обрабатывается несколькими модулями Conv и C2f для извлечения карт объектов в разных масштабах. Модуль C2f представляет собой улучшенную версию исходного модуля C3 и функционирует как основной модуль остаточного обучения. На рис. 2 изображена базовая структура алгоритма. Выходные карты объектов обрабатываются модулем Spatial Pyramid Pooling Fusion (далее – SPPF) [16]. Целью SPPF является предоставление многомасштабного представления входных карт объектов. Объединяя данные в разных масштабах, SPPF позволяет модели захватывать функции на разных уровнях абстракции. Это полезно, когда может потребоваться обнаружение объектов разных размеров.

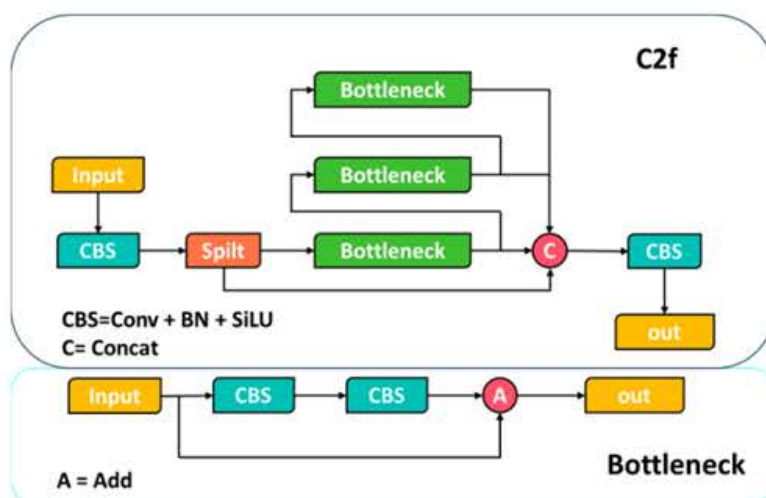


Рис. 2. Структурная схема модуля C2f

Слой шеи YOLOv8 включает структуру FPN + PAN для улучшения возможностей объединения функций модели (рис. 3). Эта структура объединяет карты объектов высокого и низкого уровня с использованием методов повышающей и понижающей дискретизации, облегчая передачу семантических функций и функций локализации. Благодаря такому подходу сеть становится лучше приспособлена для объединения функций объектов разных масштабов, тем самым повышая производительность обнаружения объектов разных масштабов.




Рис. 3. Структура FPN PAN

Расчет потерь включает в себя две составляющие: классификацию и регрессию, исключая ветвь «Объектность». Ветвь классификации использует потери двоичной перекрестной энтропии, а ветвь регрессии использует функции потерь распределения фокуса (Distribution Focal Loss – далее DFL) и CIoU.

Основная идея DFL заключается в решении проблемы дисбаланса классов в обучающих данных, что может привести к снижению производительности при обучении детекторов объектов.

Чтобы вычислить DFL для потерь локализации, предсказанные координаты рамки (x, y, w, h) дискретизируются в ячейки с использованием предварительно определенного количества шагов. Затем бины используются для расчета распределения вероятностей в диапазоне возможных значений для каждого признака. Под бином понимается модель нейрона, которая принимает двоичные значения входных данных и выдает двоичный выход. Это прогнозируемое распределение сравнивается с истинным распределением соответствующей функции, которое рассчитывается на основе точных координат объекта на изображении в обучающих данных. Затем DFL рассчитывается как взвешенная сумма отрицательного логарифма предсказанных вероятностей для положительных выборок с весами, основанными на распределении выборок для каждого бина.

Оценки классификации представлены двумерной матрицей, указывающей наличие объекта в каждом пикселе. Координаты регрессии представлены четырехмерной матрицей, указывающей отклонение центра объекта от каждого пикселя. Предсказываются два показателя: ограничительные рамки и вероятности нахождения в них нужного объекта. Размерность и положение ограничительных рамок вокруг объекта на изображении (рис. 4) вычисляются по формулам:

$$\begin{cases} b_x = \sigma(t_x) + c_x; \\ b_y = \sigma(t_y) + c_y; \\ b_w = p_w e^{t_w}; \\ b_h = p_h e^{t_h}, \end{cases} \quad (2)$$

где t_x, t_y, t_w, t_h – предсказанные координаты центра рамки;

p_w, p_h – ширина и высота рамки;

c_x, c_y – смещение ячейки от верхнего левого угла изображения.




Рис. 4. Схематическое изображение расчета положения ограничительной рамки

Наконец, YOLOv8 использует средство назначения, ориентированное на задачу, для вычисления метрики выравнивания задач с использованием оценок классификации и координат регрессии. Метрика выравнивания задач объединяет оценки классификации со значением пересечения по объединению (далее – IoU), что позволяет одновременно оптимизировать классификацию и локализацию, подавляя при этом поля прогнозирования низкого качества.

IoU вычисляется по (3):

$$IoU = \frac{\text{Область пересечения}}{\text{Область объединения}} \quad (3)$$

Эту формулу можно представить в виде рис. 5.




Рис. 5. Схематическое изображение метрики выравнивания задач IoU

Пересечение через объединение – это широко используемый показатель при обнаружении объектов, служащий для определения положительных и отрицательных образцов, а также для оценки расстояния между предсказанными блоками и основной истиной. Объект обычно классифицируется как обнаруженный, когда IoU превышает 0,5 [17, 18].

Дообучение модели машинного обучения YOLOv8 с собственным датасетом

Для решения задачи нахождения спектра деструктивного воздействия и объектов для анализа в спектре информационного сигнала требуются две модели, определяющие на изображении объекты, которые понадобятся для дальнейшей работы алгоритма.

Для удобства создания и разметки датасета используется сервис Roboflow. Разметка производится таким образом, что нужная нам рамка объекта соответствует координатам (n, x, y, w, h) , где n – номер класса объекта, x – относительная координата объекта по оси Ox , y – относительная координата объекта по оси Oy , w – относительная ширина объекта, h – относительная высота объекта.

Датасет разбит на три части: тренировочная часть, валидационная и тестовая части в отношении соответственно 85 %, 10 %, 5 %.

Обучение первой модели происходит на исходных изображениях (первый датасет), полученных с использованием анализатора спектра FSH8.

Пример разметки первого и второго датасета представлен на рис. 6.



Рис. 6. Разметка датасетов

Созданные датасеты экспортируются с платформы Roboflow в Google Colab. Обучение модели нейронной сети происходит в облачной среде Google Colab с использованием графического процессора. Для обучения модели нейронной сети необходима библиотека ultralytics, чтобы импортировать модуль YOLO. Обучение происходит на параметрах нейронной сети: $epoch=350$, $bath=8$, $patience=0$. Epoch – аргумент, характеризующий количество прохода датасета через нейронную сеть в прямом и обратном направлении. Под bath понимается число тренировочных объектов. Patience используется для остановки обучения модели нейронной сети, если результат с каждой эпохой не меняется. Значение 0 означает, что остановки не произойдет.

После завершения обучения получаем графики, характеризующие зависимость ошибок от количества эпох обучения моделей, которые представлены на рис. 7.




Рис. 7. График обучения модели на основе первого датасета

На графике видно насколько хорошо модель может найти объект внутри ограничивающей рамки, что соответствует box_loss . Cls_loss отвечает за правильную классификацию обнаруженных объектов. Dfl_loss используется для устранения дисбаланса классов в процессе обнаружения объектов. По отдельности каждая из этих потерь отражает отдельный аспект процесса обнаружения объекта. Все они вносят свой вклад в общие потери модели, которые, по сути, отражают общую производительность модели по всем этим аспектам.

Разработка интеллектуального программного модуля (скрипта) для автоматического анализа характеристик спектра информационного сигнала

Механизм анализа ширины спектра и мощности деструктивного воздействия при обработке спектра информационного сигнала с применением алгоритмов искусственного интеллекта. Для разработки механизма, позволяющего анализировать ширину спектра и мощность деструктивного воздействия в спектре информационного сигнала, воспользуемся программным обеспечением Tesseract и разработанными моделями машинного обучения, предсказывающими координаты рамки. Указанное программное обеспечение будем использовать для распознавания текста на изображениях.

Механизм анализа ширины спектра и мощности деструктивного воздействия в спектре информационного сигнала представляет собой четырехэтапный алгоритм (рис. 8):

- на первом этапе необходимо подать на вход одно изображение или папку с изображениями, подвергаемыми анализу;
- на втором этапе, используя модели машинного обучения, происходит обнаружение рамок объектов и сохранение их в отдельные папки;
- на третьем этапе происходит распознавание текста на анализируемых изображениях;
- на четвертом этапе формируются количественные показатели ширины спектра и мощности деструктивного воздействия в спектре информационного сигнала.

На основе обнаружения объектов, разработанных моделей машинного обучения и программного обеспечения распознавания текста разработан интеллектуальный программный модуль (скрипт),

позволяющий автоматически анализировать характеристики деструктивного воздействия в спектре информационного сигнала (рис. 9).



Рис. 8. Блок-схема алгоритма автоматического анализа характеристик спектра деструктивного воздействия

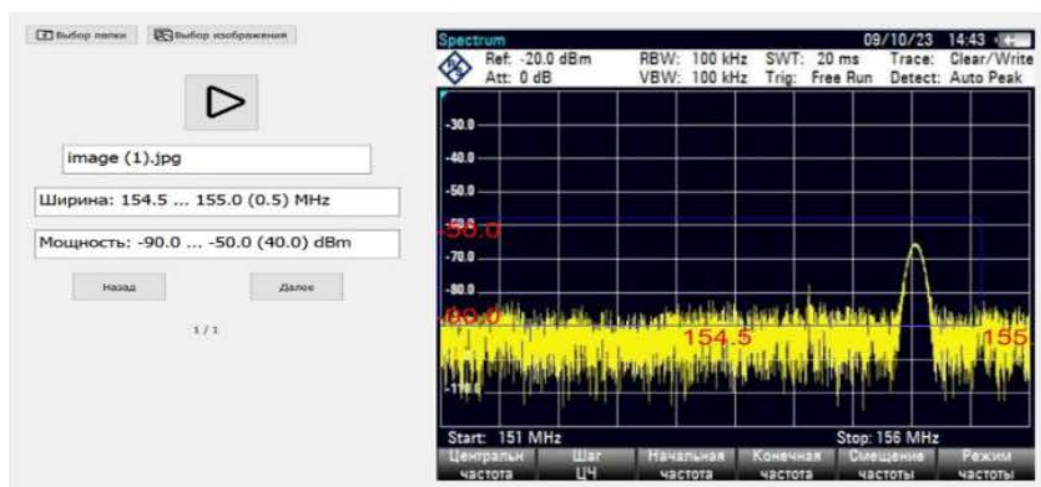


Рис. 9. Пример работы интеллектуального программного модуля (скрипта) для автоматического анализа спектра информационного сигнала

Выводы

В работе предложен способ реализации интеллектуального программного модуля на основе аппарата нейронных сетей для визуализации и автоматического анализа характеристик спектров информационного сигнала и деструктивных воздействий. Приведена процедура выбора и создания модели машинного обучения, позволяющей выявлять наличие деструктивного воздействия и его признаков. Разработаны алгоритм выделения характеристик мощности и ширины спектра деструктивного воздействия в спектре информационного сигнала и интеллектуальный программный модуль (скрипт) для их автоматического анализа. Механизм анализа ширины спектра и мощности деструктивного воздействия при обработке спектра информационного сигнала интеллектуальным программным модулем зарегистрирован, и получено свидетельство о государственной регистрации программы для ЭВМ [17]. Предложенный программный модуль может применяться в системах железнодорожной радиосвязи для обеспечения бесперебойного обмена информацией между диспетчером и подвижным составом за счет автоматизации мониторинга спектров информационных сигналов и своевременного обнаружения деструктивных воздействий с использованием технологии искусственного интеллекта.

Список литературы

1 Хохлов, Н. С. Анализ некоторых уязвимостей информационной безопасности системы беспроводной связи стандарта DMR / Н. С. Хохлов, С. В. Канавин, И. В. Гилев // Вестник Воронежского института МВД России. – 2022. – № 1. – С. 9–17. – ISSN 2071-3584.

2 Хохлов, Н. С. Модель противодействия угрозам разрушения информации в системах связи специального назначения при деструктивных воздействиях / Н. С. Хохлов, С. В. Канавин, И. В. Гилев // Вестник Воронежского института МВД России. – 2023. – № 1. – С. 106–117. – ISSN 2071-3584.

3 Оптическое распознавание символов в Raspberry Pi с помощью Tesseract. – URL: <https://microkontroller.ru/raspberrypiprojects/opticheskoe-raspoznavanie-simvolov-v-raspberry-pi-s-pomoshhyu-tesseract> (дата обращения: 18.10.2023).

4 Сирота, А. А. Анализ алгоритмов поиска объектов на изображениях с использованием различных модификаций сверточных нейронных сетей / А. А. Сирота, Е. Ю. Митрофанова, А. И. Милованова // Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии. – 2019. – № 3. – С. 123–137. – ISSN 1995-5499.

5 Чорбаа, Н. А. Сравнительный анализ методов детектирования объектов на радиолокационных изображениях при помощи нейронных сетей / Н. А. Чорбаа, А. Ту. Ле, И. М. Толстой // Научный результат. Информационные технологии. – 2020. – Т. 5, № 4. – С. 15–25. – ISSN 2518-1092.

6 Применение искусственных нейронных сетей для анализа мультиспектральных изображений / М. Ю. Альес, Е. А. Антонов, А. И. Калугин, М. Р. Зарипов // Оптический журнал. – 2021. – Т. 88, № 8. – С. 48–53. – ISSN 1023-5086.

7 Черниговский, А. В. Нейронные сети как инструмент анализа сетевого трафика / А. В. Черниговский, М. В. Кривов // Вестник Ангарского государственного технического университета. – 2019. – № 13. – С. 151–157. – DOI 10.36629/2686-777x-2019-1-13-151-157.

8 К вопросу обеспечения защищенного доступа к информационным системам с применением биометрической аутентификации на основе нечеткого образа личности пользователя и нейросетевых преобразований. / О. И. Бокова, С. В. Канавин, Н. С. Хохлов [и др.] // Вестник Дагестанского государственного технического университета. Технические науки. – 2023. – № 50 (4). – С. 75–84. – DOI 10.21822/2073-6185-2023-50-4-75-84.

References

1 Khokhlov, N. S. Analysis of some information security vulnerabilities of the wireless communication system of the DMR standard / N. S. Khokhlov, S. V. Kanavin, I. V. Gilev // Bulletin of the Voronezh Institute of the Ministry of Internal Affairs of Russia. – 2022. – No. 1. – P. 9–17. – ISSN 2071-3584.

2 Khokhlov, N. S. Model of countering threats of information destruction in special-purpose communication systems under destructive influences / N. S. Khokhlov, S. V. Kanavin, I. V. Gilev // Bulletin of the Voronezh Institute of the Ministry of Internal Affairs of Russia. – 2023. – No. 1. – P. 106–117. – ISSN 2071-3584.

3 OCR on Raspberry Pi using Tesseract. – URL: <https://microkontroller.ru/raspberrypiprojects/opticheskoe-raspoznavanie-simvolov-v-raspberry-pi-s-pomoshhyu-tesseract> (date of access: 10/18/2023).

4 Sirota, A. A. Analysis of algorithms for searching objects in images using various modifications of convolutional neural networks / A. A. Sirota, E. Yu. Mitrofanova, A. I. Milovanova // Bulletin of Voronezh State University. Series: System analysis and information technologies. – 2019. – No. 3. – P. 123–137. – ISSN 1995-5499.

5 Chorbaa, N. A. Comparative analysis of methods for detecting objects on radar images using neural networks / N. A. Chorbaa, A. Tu. Le, I. M. Tolstoy // Scientific result. Information Technology. – 2020. – Vol. 5, No. 4. – P. 15–25. – ISSN 2518-1092.

6 Application of artificial neural networks for the analysis of multispectral images / M. Yu. Alyes, E. A. Antonov, A. I. Kalugin, M. R. Zaripov // Optical Journal. – 2021. – Vol. 88, No. 8. – P. 48–53. – ISSN 1023-5086.

7 Chernigovsky, A. V. Neural networks as a tool for analyzing network traffic / A. V. Chernigovsky, M. V. Krivov // Bulletin of the Angarsk State Technical University. – 2019. – No. 13. – P. 151–157. – DOI 10.36629/2686-777x-2019-1-13-151-157.

8 On the issue of ensuring secure access to information systems using biometric authentication based on a fuzzy image of the user's personality and neural network transformations. / O. I. Bokova, S. V. Kanavin, N. S. Khokhlov [et al.] // Bulletin of the Dagestan State Technical University. Technical science. – 2023. – No. 50 (4). – P. 75–84. – DOI 10.21822/2073-6185-2023-50-4-75-84.

9 Фисун, В. В. Искусственный интеллект управления информационной безопасностью объектов критической информационной инфраструктуры: монография / В. В. Фисун. – Москва : Русайнс, 2023. – 360 с. – ISBN 9785436597232.

10 Климов, С. М. Противодействие компьютерным атакам. Методические основы / С. М. Климов, М. П. Сычев, А. В. Астрахов. – Москва : МГТУ имени Н. Э. Баумана, 2013. – 108 с.

11 Шелухин, О. И. Сетевые аномалии. Обнаружение, локализация, прогнозирование: монография / О. И. Шелухин. – Москва : Горячая линия – Телеком, 2020. – 447 с. – ISBN 978-5-9912-0756-0.

12 Элбон, К. Машинное обучение с использованием Python. Сборник рецептов : перевод с английского / К. Элбон. – Санкт-Петербург : БХВ-Петербург, 2019. – 384 с. – ISBN 978-5-9775-4056-8.

13 FSH8 портативный анализатор спектра. – URL: <https://www.samarapribor.ru/main/fsh8.html> (дата обращения: 18.10.2023).

14 BL-YOLOv8 : An Improved Road Defect Detection Model Based on YOLOv8. – URL: <https://www.mdpi.com/1424-8220/23/20/8361#B19-sensors-23-08361> (дата обращения: 18.10.2023).

15 Преснецов, А. М. Разработка программно-аппаратного комплекса для мониторинга производственной деятельности с использованием нейросети YOLOV8 / А. М. Преснецов, А. П. Тюрин // Интеллектуальные системы в производстве. – 2023. – Т. 21, № 2. – С. 140–151. – ISSN 1813-7911.

16 Свидетельство о государственной регистрации программы для ЭВМ RU, № 2023688381. Интеллектуальный программный модуль для автоматизированного анализа характеристик спектров информационного сигнала и деструктивных воздействий. / Р. В. Ртищев, И. В. Гилев, С. В. Канавин, Н. С. Хохлов. – № 2023687782 ; заявл. 08.12.2023 ; опублик. 21.12.2023, Бюл. № 1. – 1 с.

17 Постолит, А. В. Основы искусственного интеллекта в примерах на Python. Самоучитель / А. В. Постолит. – 2-е изд., перераб. и доп. – Санкт-Петербург : БХВ-Петербург, 2024. – 448 с. – ISBN 978-5-9775-1818-5.

9 Fisun, V. V. Artificial intelligence for managing information security of critical information infrastructure objects: monograph / V. V. Fisun. – Moscow : Rusigns, 2023. – 360 p. – ISBN 9785436597232.

10 Klimov, S. M. Countering computer attacks. Methodological foundations. / S. M. Klimov, M. P. Sychev, A. V. Astrakhov. – Moscow : MSTU named after N. E. Bauman, 2013. – 108 p.

11 Shelukhin, O. I. Network anomalies. Detection, localization, forecasting: monograph / O. I. Shelukhin. – Moscow : Hotline – Telecom, 2020. – 447 p. – ISBN 978-5-9912-0756-0.

12 Albon, K. Machine learning using Python. Collection of recipes : Transl. from English / K. Elbon. – Saint Petersburg : BHV-Petersburg, 2019. – 384 p. – ISBN 978-5-9775-4056-8.

13 FSH8 portable spectrum analyzer. – URL: <https://www.samarapribor.ru/main/fsh8.html> (date of access: 10/18/2023).

14 BL-YOLOv8 : An Improved Road Defect Detection Model Based on YOLOv8. – URL: <https://www.mdpi.com/1424-8220/23/20/8361#B19-sensors-23-08361> (date of access: 10/18/2023).

15 Presnetsov, A. M. Development of a hardware and software complex for monitoring production activities using the YOLOV8 neural network / A. M. Presnetsov, A. P. Tyurin // Intelligent systems in production. – 2023. – Vol. 21, No. 2. – P. 140–151. – ISSN 1813-7911.

16 Certificate of state registration of the computer program RU, No. 2023688381 dated December 21, 2023. Intelligent software module for automated analysis of the characteristics of information signal spectra and destructive influences. / R. V. Rtishchev, I. V. Gilev, S. V. Kanavin, N. S. Khokhlov // No. 2023687782 ; application 12.08.2023, Bulletin. No. 1. – 1 p.

17 Postolit, A. V. Fundamentals of artificial intelligence in examples in Python. Self-instruction manual / A. V. Postolit. – 2nd ed., revised. and additional. – Saint Petersburg : BHV-Petersburg, 2024. – 448 p. – ISBN 978-5-9775-1818-5.

N. S. Khokhlov, O. I. Bokova, S. V. Kanavin, I. V. Gilev, R. V. Rtischev

DEVELOPMENT OF AN INTELLIGENT SOFTWARE MODULE BASED ON NEURAL NETWORKS FOR VISUALIZATION AND AUTOMATIC ANALYSIS OF CHARACTERISTICS OF INFORMATION SIGNAL SPECTRA AND DESTRUCTIVE IMPACTS

Abstract. The paper proposes a method for implementing an intelligent software module based on neural networks for visualization and automatic analysis of the characteristics of information signal spectra and destructive influences. A procedure is given for selecting and creating a machine learning model that allows identifying the presence of destructive effects and its signs. The neural network model is trained in a cloud environment using a GPU. A

specialized library was used to train the neural network model. Training is implemented on the parameters of the neural network, which characterize the number of times the dataset passes through the neural network in the forward and reverse directions. As a result of training, graphs were obtained characterizing the dependence of errors on the number of epochs of model training. An algorithm for identifying power characteristics, the width of the spectrum of destructive effects in the spectrum of an information signal, and an intelligent software module (script) for their automatic analysis has been developed. The mechanism for analyzing the spectrum width and power of destructive influence in the spectrum of an information signal includes software and machine learning models for recognizing text in images.

Keywords: intelligent software module; neural networks; automatic analysis of spectrum characteristics; destructive effects; machine learning model; an algorithm for automatic analysis of the characteristics of the information signal spectrum.

For citation: Development of an intelligent software module based on neural networks for visualization and automatic analysis of characteristics of information signal spectra and destructive impacts / N. S. Khokhlov, O. I. Bokova, S. V. Kanavin [et al.] // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2024. – No. 1. – P. 158–168. – DOI 10.46973/0201-727X_2024_1_158.

Сведения об авторах

Хохлов Николай Степанович

Воронежский институт МВД России,
кафедра «Инфокоммуникационных систем
и технологий»,
доктор технических наук, профессор,
e-mail: nikolayhohlov@rambler.ru

Бокова Оксана Игоревна

ООО «Каскад»,
доктор технических наук, профессор,
научно-технический консультант,
e-mail: o.i.bokova@gmail.com

Канавин Сергей Владимирович

Воронежский институт МВД России,
кафедра «Инфокоммуникационных систем
и технологий»,
кандидат технических наук, доцент,
e-mail: sergejj-kanavin@rambler.ru

Гилев Игорь Владимирович

Воронежский институт МВД России,
кафедра «Инфокоммуникационных систем
и технологий»,
преподаватель,
e-mail: gileviv@bk.ru

Ртищев Роман Владимирович

Воронежский институт МВД России,
кафедра «Инфокоммуникационных систем
и технологий»,
курсант радиотехнического факультета,
e-mail: gileviv@bk.ru

Information about the authors

Khokhlov Nikolai Stepanovich

Voronezh Institute of the Ministry of
Internal Affairs of Russia,
Chair «Infocommunication Systems
and Technologies»,
Doctor of Engineering Sciences, Professor,
e-mail: nikolayhohlov@rambler.ru

Bokova Oksana Igorevna

Cascade LLC,
Doctor of Engineering Sciences, Professor,
Scientific and Technical Consultant,
e-mail: o.i.bokova@gmail.com

Kanavin Sergey Vladimirovich

Voronezh Institute of the Ministry of
Internal Affairs of Russia,
Chair «Infocommunication Systems
and Technologies»,
Candidate of Engineering Sciences,
Associate Professor,
e-mail: sergejj-kanavin@rambler.ru

Gilev Igor Vladimirovich

Voronezh Institute of the Ministry of
Internal Affairs of Russia,
Chair «Infocommunication Systems
and Technologies»,
Lecturer,
e-mail: gileviv@bk.ru

Rtischev Roman Vladimirovich

Voronezh Institute of the Ministry of
Internal Affairs of Russia,
Chair «Infocommunication Systems and
Technologies»,
Cadet of the Radio Engineering Faculty,
e-mail: gileviv@bk.ru