

А.С. Кириллов

**ДЕМОДУЛЯЦИЯ СИГНАЛА С ПОМОЩЬЮ КЛАССИЧЕСКИХ АЛГОРИТМОВ
МАШИННОГО ОБУЧЕНИЯ ДЛЯ МОДЕЛИ ВАТТЕРСОНА**

Исследуется возможность применения классических алгоритмов машинного обучения для демодуляции сигналов в коротковолновом канале связи, описываемом моделью Ваттерсона. Актуальность задачи обусловлена необходимостью повышения помехоустойчивости при широкополосной передаче данных в условиях многолучевого распространения и доплеровских искажений. В качестве классификаторов используются алгоритмы Random Forest, Decision Tree и KNN (к-ближайших соседей). Обучение моделей производится на синтезированных данных, полученных в среде MATLAB Simulink, где варьировались временные задержки лучей (0–4 мс) и доплеровский сдвиг (0–10 Гц). Входными признаками служат координаты сигнальных созвездий, а также предыстория принимаемых символов, поскольку межсимвольная интерференция оказывает существенное влияние на положение текущей точки. Проведенные эксперименты выявили критическую особенность: алгоритмы демодуляции обладают высокой чувствительностью к изменениям доплеровского сдвига. Отклонение параметра всего на 0.1 Гц от обучающей выборки приводит к изменению структуры сигнального созвездия и росту вероятности ошибки (BER) до 0.5. При совпадении доплеровских параметров с обучающей сеткой наилучшие результаты показывает алгоритм Random Forest, обеспечивая BER < 0.01 на полном объеме данных. Для решения проблемы чувствительности предложен метод локального обучения с уменьшенным шагом дискретизации доплеровского сдвига (до 0.1 Гц), что позволяет добиться BER ≤ 0.01 для Random Forest. В связи с экспоненциальным ростом объема обучающей выборки (до 1000 Гб) разработаны методы её сокращения: исключение временных параметров и семплирование данных с учетом возможных комбинаций предшествующих битов. Это позволило уменьшить объем данных в 31.5 раза, сохранив BER < 10% для Random Forest при шаге обучения 0.2 Гц. В работе делается вывод о целесообразности использования Random Forest Classifier для демодуляции в КВ-каналах и необходимости адаптации шага обучения под требуемую точность доплеровского сдвига.

Модель Ваттерсона; коротковолновый канал связи; Matlab; машинное обучение; многолучевой канал связи.

A.S. Kirillov

**SIGNAL DEMODULATION USING CLASSICAL MACHINE LEARNING
ALGORITHMS FOR THE WATTERSON MODEL**

This paper investigates the application of classical machine learning algorithms for signal demodulation in a high-frequency communication channel described by the Watterson model. The relevance of this task stems from the need to improve noise immunity during broadband data transmission under conditions of multipath propagation and Doppler distortions. The classifiers used include Random Forest, Decision Tree, and k-nearest neighbors (KNN). The models are trained on synthesized data generated in the MATLAB Simulink environment, with varying path delays (0–4 ms) and Doppler shifts (0–10 Hz). The input features comprise the coordinates of signal constellations as well as the history of received symbols, since intersymbol interference significantly affects the position of the current point. The experiments revealed a critical feature: demodulation algorithms exhibit high sensitivity to variations in Doppler shift. A deviation of just 0.1 Hz from the training set parameters alters the structure of the signal constellation, increasing the bit error rate (BER) to 0.5. When the Doppler parameters align with the training grid, the Random Forest algorithm demonstrates the best performance, achieving a BER < 0.01 on the full dataset. To address this sensitivity, a local training method with a reduced Doppler shift sampling step (down to 0.1 Hz) is proposed, enabling a BER ≤ 0.01 for Random Forest. Due to the exponential growth of the training dataset size (up to 1000 GB), data reduction techniques were developed: excluding time parameters and sampling data based on possible combinations of preceding bits. This reduced the data volume by a factor of 31.5 while maintaining a BER < 10% for Random Forest with a training step of 0.2 Hz. The study concludes that the Random Forest classifier is suitable for demodulation in HF channels and highlights the necessity of adapting the training step to the required Doppler shift accuracy.

Watterson model; shortwave communication channel; Matlab; machine learning; multipath communication channel.

Введение. Коротковолновые (КВ) каналы связи используются уже давно. Главным плюсом является свойство волн КВ диапазона отражаться от ионосферы, тем самым передавать данные на сотни километров без инфраструктуры. Это позволяет использовать их в чрезвычайных ситуациях, например в спасательных операциях или для экспедиций.

На сегодняшний день актуально увеличение скорости передачи данных таким способом связи. Для этого можно использовать широкополосную передачу данных, однако, в таком случае необходимо бороться с новыми видами помех в канале, связанных с отражением выбранного сигнала от ионосферы. Получающиеся помехи описывает модель Ваттерсона, использующая многолучевой канал связи [1]. С помощью нее можно смоделировать интересующий канал связи и исследовать поведение сигнала во времени.


В работе решается задача повышения точности демодуляции широкополосного сигнала в ионосферном канале связи. В качестве решения были выбраны классические алгоритмы машинного обучения и построен классификатор, который по принятым сигналам созвездиям (с учетом межсимвольной интерференции) восстанавливает переданную битовую последовательность в широком диапазоне параметров Ваттерсона.

В современных задачах приема сигнала все чаще используют машинное обучение [2–10]. Данные методы применяются как для работы с каналом для его анализа и определения ранее неизвестных параметров, так для работы с принимаемым сигналом для его демодуляции или исследования характерных параметров. В поставленной задаче также выдвигалась идея использования машинного обучения [11–14]. Однако решения, которое позволило бы использовать широкополосный коротковолновый канал связи в широкой эксплуатации, все еще нет.

Предложенная работа продолжает исследования [15–18], рассматривая демодулятор с использованием методов машинного обучения. Ключевое отличие в текущей работе заключается в использовании предобучающих выборок данных и алгоритмов, построенных на этих данных.

1. Модель канала связи. Выбранная модель канала была смоделирована в программе Matlab, среде Simulink. Она была описана в работах [15, 16]. Отдельно был реализован блок модели Ваттерсона с возможностью изменять параметры канала связи. Он представляет из себя многолучевой канал связи с блоками временной задержки и доплеровского сдвига.

Для обучения были выбраны данные для канала с допустимыми параметрами: время задержки от 0 до 4 мс с шагом в 1 мс, а сдвиг Доплера от 0 до 10 Гц с шагом в 1 Гц. Такие характеристики канала подходят для большинства случаев передачи данных [19, 20]. Общая модель канала изображена на картинке 1, на которой выделен блок модели канала Ваттерсона красным цветом.



Модель коротковолнового канала в Matlab с блоком модели Ваттерсона

Рассматриваемые в дальнейшем программы призваны заменить блок BPSK демодулятора на картинке 1, который показывает BER ~ 0.5 при различных параметрах канала Ваттерсона. При успешной их настройке можно будет утверждать о демодуляции широкополосного сигнала при различных параметрах рассматриваемого канала связи. Выходы out.ml и out.in созданы для набора данных для обучения.

2. Машинное обучение на полном объеме данных. Общий объем информации для обучения составит чуть больше 1 Гб. Для облегчения вычислительной нагрузки и исследования характеристик обучения создадим 4 датасета: с полными данными, с половиной

данных (каждый второй принимаемый символ), $1/5$ данных и $1/10$. Алгоритм будет работать с принимаемыми точками сигнальных созвездий на принимающем устройстве. В качестве признаков подаются координаты принимаемой точки, параметры канала, а также координаты точек, которые были приняты ранее с задержками, указанными в параметрах канала. Также передается номер переданного символа в последовательности. Эти данные необходимы, так как на положение текущего символа влияют символы, переданные ранее. Ответом такой программы будет 1 или 0 – значение, которое передал источник, как показано в табл. 1.

Таблица 1

Пример принимаемых данных для обучения, где signal – ответ программы

T2	T3	FO1	FO2	FO3	ml_real	ml_imag	ml_real t2	ml_imag t2	ml_real t3	ml_imag t3	n	signal
46000	82000	2000	4000	6000	-1016	1	1897	-285	-1128	-1507	100	1
46000	82000	2000	4000	6000	-1002	-6	-1099	-1561	-794	2041	101	1
46000	82000	2000	4000	6000	1011	5	57	-125	800	-2036	102	0
46000	82000	2000	4000	6000	-988	-5	876	-1978	1869	-345	103	1

Важность учета полученных ранее символов показана на рис. 1 и 2, где изображены геометрические места точек во времени, соответствующие 0 при наложении двух 0, переданных ранее (рис. 1) и 0 при наложении двух 1, переданных ранее (рис. 2).




Рис. 1. Геометрическое расположение 0 при влиянии на него двух 0, переданных ранее




Рис. 2. Геометрическое расположение 0 при влиянии на него двух 1, переданных ранее

В качестве проверки работы алгоритмов взят канал с параметрами $t_1 = 0$ мс, $t_2 = 2$ мс, $t_3 = 3$ мс, $f_{o1} = 2$ Гц, $f_{o2} = 4$ Гц, $f_{o3} = 6$ Гц – тестовый сигнал номер 1. Он попадает в сетку обучения, но данные, переданные по этому каналу, отличаются от тех, что были переданы в обучающих выборках. Демодулятор на прием получает не только сигнал, но и параметры канала, при которых данный сигнал был передан [15, 16]. В качестве рассматриваемых алгоритмов машинного обучения были взяты KneighborsClassifier (knn), Decision Tree Classifier и Random Forest Classifier, определенные в статьях [7, 8]. Результат их работы для каждого датасета показан в табл. 2 как показатель ошибки на бит (BER) для принимаемого тестового сигнала номер 1.

Таблица 2

BER тестового сигнала для каждого алгоритма в зависимости от количества данных

	Полные данные	½ данных	1/5 данных	1/10 данных
KneighborsClassifier	0.05	0.15	0.27	0.37
Decision Tree Classifier	0.01	0.07	0.11	0.25
Random Forest Classifier	<0.01	0.04	0.09	0.19

Как видно из табл. 2, алгоритм KneighborsClassifier дает приемлемые результаты только при полном количестве данных. Random Forest Classifier может работать и с половиной данных, но наибольшую точность развивает на всех данных, как и Decision Tree Classifier. В результате BER рассматриваемого принятого сигнала будет меньше 1%. Это не зависит от конкретного сигнала, но распространяется лишь на канал в установленных значениях параметров.

Теперь в качестве тестовой передачи возьмем канал с параметрами $t_1 = 0$ мс, $t_2 = 2$ мс, $t_3 = 3$ мс, $f_{o1} = 2.5$ Гц, $f_{o2} = 4.3$ Гц, $f_{o3} = 6$ Гц – тестовый сигнал номер 2. То есть данный канал очень похож на предыдущий тестовый, но с небольшими отклонениями по доплеровскому сдвигу. Заметим, что этот набор параметров не ложится в сетку обучающей выборки. И для него BER принимаемого сигнала алгоритмом Random Forest Classifier будет равняться ~0.5, вне зависимости от количества обучающих данных. Аналогичный результат покажут алгоритмы Decision Tree Classifier и KneighborsClassifier. Чтобы понять причину неудачи алгоритма, рассмотрим геометрическое множество точек 0 на сигнальном созвездии для тестового сигнала номер 1 и 2, отображенное на рис. 3 и 4.




Рис. 3. Сигнальные созвездия тестового сигнала номер 1 для 0




Рис. 4. Сигнальные созвездия тестового сигнала номер 2 для 0

Как можно видеть из рис. 3 и 4 сигнальные созвездия сильно изменяются даже при небольших изменениях параметров доплеровского сдвига. Параметры при тестовом сигнале номер 1 совпадали с сеткой обучения, а значит характер сигнального созвездия был

заложен в обучающую выборку. У тестового сигнала номер 2 параметры не попали на обучающие данные, из-за чего рисунок данного сигнала не был внесен в обучающие данные, при этом сильно отличался от уже известных. Это означает, что преобразования доплеровского сдвига на десятые доли герца влияют на характер сигнальных созвездий и необходимо обучать алгоритмы на меньшем шаге данного параметра для выявления критических изменений в их поведении.

Вернемся к изначальному тестовому сигналу номер 1 и поменяем в нем временную задержку, а доплеровский сдвиг оставим прежним. Теперь $t_2 = 2.1$ мс, $t_3 = 3.4$ мс, а все остальные параметры те же. Данный сигнал не попадает в обучающую сетку, однако BER принимаемого сигнала будет таким же как в табл. 2. Построив сигнальные созвездия для получившегося сигнала и изначального, получим аналогичные картины, что соответствует результатам успешной демодуляции нового сигнала. Данную закономерность подтверждают многочисленные изменения временных параметров канала, не меняя результата. Небольших же изменений (~ 0.1 Гц) доплеровского сдвига оказывается достаточно, чтобы испортить работу алгоритмов демодуляции. Таким образом, получаем значительные преобразования сигнала при изменении сдвига Доплера на десятые доли герца, тогда как временные сдвиги такого эффекта не производят.

3. Обучение на локальных данных. Так как основным критерием изменения рисунка сигнального созвездия является доплеровский сдвиг, установим меньший шаг его изменения для обучающей выборки. Временные же параметры оставим прежними.

В качестве примера опять зафиксируем тестовый сигнал номер 1 и рассмотрим данные для обучения для параметров $t_1 = 0$ мс, $t_2 =$ от 1 до 3 мс с шагом в 0.5 мс, $t_3 =$ от 2 до 4 мс с шагом в 0.5 мс, $f_{o1} =$ от 1.7 до 2.7 Гц с шагом в 0.2 Гц, $f_{o2} =$ от 3.7 до 4.3 Гц с шагом в 0.2 Гц, $f_{o3} =$ от 5.7 до 6.3 Гц с шагом в 0.2 Гц для установки рассматриваемого сигнала как центрального (среднего значения для выбранной передачи данных).

Алгоритмы на такой обучающей выборке показывают результаты BER для всех сигналов, лежащих в рассматриваемой области, ~ 0.13 для Decision Tree Classifier и KneighborsClassifier. Алгоритм Random Forest Classifier показывает BER ~ 0.08 . При этом все тестируемые сигналы не принадлежат обучающей сетке параметров. Общий результат BER от шага обучающей выборки можно рассмотреть в табл. 3, где показано улучшение демодуляции при уменьшении шага обучающей выборки.

Таблица 3

BER тестового сигнала для каждого алгоритма в зависимости от шага обучающих данных

	0.1 Гц	0.2 Гц	0.5 Гц	1 Гц
KneighborsClassifier	0.06	0.13	0.35	0.5
Decision Tree Classifier	0.03	0.12	0.29	0.5
Random Forest Classifier	<0.01	0.08	0.26	0.44

Это означает, что удалось подобрать шаг доплеровского сдвига, за который сигнал не меняется настолько, что его нельзя демодулировать обученной моделью.

4. Обучение с необходимым шагом для всего объема данных. Полный набор данных, который был приведен в самом начале занимает 1 Гб. При этом шаг обучения в нем был равен 1 Гц. Необходимо выяснить какой объем данных будет занимать такая же обучающая выборка с шагом в 0.1 Гц, которая сможет демодулировать любой принимаемый сигнал, как описано в главе 3.

Обучение происходит по правилу $f_{o1} \leq f_{o2} \leq f_{o3}$. В таком случае, если у нас есть n значений f_{o1} , мы получим $n * (n + 1) * (n + 2) / 6$ вариантов комбинаций параметров. Влияние параметров времени мы сейчас рассматривать не будем. Уменьшение шага обучения увеличит количество рассматриваемых параметров f_{o1} пропорционально отноше-

нию прежнего шага (1 Гц) к новому (0.1 Гц), т.е. в 10 раз. Это означает, что итоговый объем обучающей выборки с принятым шагом будет весить ~ 1000 Гб, что слишком много для нашей задачи. Если аналогично взять шаг 0.2 Гц, то получим ~ 125 Гб, что все еще слишком много.

Необходимо пересмотреть обучающие данные, уменьшив их так, чтобы не оказать влияния на качество демодуляции. Для начала используем Random Forest Classifier и его внутренние функции, чтобы определить значимость каждого параметра для определения классификации принимаемых точек. Изучая эти данные, обнаружится, что параметры времени – t_1, t_2, t_3 не обязательны для классификации выбранных объектов. При некоторых комбинациях параметров удаление этих данных из обучения повышает качество демодуляции. При этом сами параметры времени на самом деле никуда не ушли – они заложены в координатах воздействующих точек. Поэтому на общем объеме данных временные параметры можно удалить из обучающих данных.

Следующий прием – как рассматривалось ранее, можно использовать не все данные, а лишь их часть. Тогда страдает качество демодуляции сигнала, увеличивается BER, однако, ухудшение приема сигнала при таком исходе можно сгладить. Для этого нужно контролировать, какие точки мы выбрасываем, а какие оставляем для обучения.

Как было показано ранее, важно не только какой бит принимаем в данный момент времени, но и какие биты были до этого, в определенный известный нам момент времени. То есть на принимаемый символ влияет символ от задержки t_2 и t_3 . Это означает, что на самом деле на прием поступает не 1 или 0, то есть 2 символа, а 000, 001 и так далее, то есть 8 символов. Это показано на рис. 5, где явно видны 8 траекторий точек сигнальных созвездий, 4 для принимаемой единицы и 4 для нуля.

Благодаря специальному выбору можно уменьшить получаемое количество данных в обучающую выборку без значительного вреда для анализа данных. Как было показано ранее, уменьшение обучающих данных в 10 раз случайным образом ухудшает работу демодулятора на основе алгоритма Random Forest Classifier до значения BER = 0.19. При использовании предложенного алгоритма данный вид демодулятора имеет показатель BER = 0.14. При этом количество данных будет уменьшено более чем в 31.5 раз. Выбранные точки данным алгоритмом изображены на рис. 6. Они соответствуют точкам с рис. 5, но их в 31.5 раз меньше, а общий вид закономерности не изменяется.




Рис. 5. Сигнальное созвездие из 0 и 1, демонстрирующее различие между битами в зависимости от предшествующих им бит




Рис. 6. Сигнальное созвездие из 0 и 1 с выборочными точками для уменьшения объема данных для обучения

Используя все приведенные методы для уменьшения объема обучающей выборки, получается добиться для Random Forest Classifier BER <10% для шага 0.2 Гц и полного объема данных. Эта обучающая выборка для тестового набора будет выглядеть как изображено на рис. 7, что соответствует рисунку 3, в котором находятся все данные без исключений.




Рис. 7. Сигнальное созвездие из 0 и 1 с выборочными точками для уменьшения объема данных для обучения в параметрах тестового сигнала номер 1

Выводы. Рассмотрены программы демодуляции сигнала на основе алгоритмов машинного обучения, были проанализированы и улучшены базы данных для решения поставленной задачи. Были выявлены два главных подхода, возникающих из-за ограниченности объема обучающих данных – локальное обучение в некоторой окрестности и обучение на полном объеме данных с уменьшенным шагом обучения и изъятием некоторых данных.

Для обучающей выборки был определен рекомендуемый шаг обучения для параметров доплеровского сдвига и временной задержки, найдена качественная зависимость шага обучения и BER.

Из-за объема конечной обучающей модели рекомендуется использовать локальное обучение на рассматриваемых параметрах. При шаге в 0.1 Гц BER алгоритма Random Forest Classifier достигает 0.01.

В случаях, когда необходимо использовать данные из всего набора параметров, результат работы алгоритма Random Forest Classifier верно определил значение полученного бита с вероятностью более чем 90%.

В будущем планируется исследовать точность локальных алгоритмов и перенести их на полный набор данных с соблюдением требования по памяти обучающих данных.

Финансирование (при наличии): ПАО «Радиофизика» (Москва, Россия), МФТИ.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Watterson C.C., Juroshek J.R., Bensema W.D. Experimental confirmation of an HF channel model // IEEE(R) Trans. commun. Technol. – 1970. – No. Dec. 6. – Vol. COM-18. – P. 792-803.
2. O'shea T., Hoydis J. An introduction to deep learning for the physical layer // IEEE Transactions on Cognitive Communications and Networking. – 2017. – Vol. 3, No. 4. – P. 563-575.
3. Song M., Song X., Qin K. Signal Detection and Demodulation Algorithm Based on Deep Learning in Communication Network // 2024 3rd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS). – IEEE, 2024. – P. 461-466.
4. Fang L., Wu L. Deep learning detection method for signal demodulation in short range multipath channel // 2017 IEEE 2nd International Conference on Opto-Electronic Information Processing (ICOIP). – IEEE, 2017. – P. 16-20.
5. Ерохин С.Д., Чадов Т.А., Журавлев А.П. Особенности формирования обучающей и тестовой выборок для алгоритмов машинного обучения, используемых при оптимизации работы приемных устройств // DSPA: Вопросы применения цифровой обработки сигналов. – 2020. – Т. 10, № 1. – С. 9-14.
6. Малыгин И.В. и др. Применение методов машинного обучения для классификации радиосигналов // Тр. МАИ. – 2017. – № 96. – С. 15.
7. Чирков О.Н., Пирогов А.А. Применение алгоритмов машинного обучения в задаче оценки беспроводного канала связи с OFDM // Вестник Воронежского государственного технического университета. – 2023. – Т. 19, № 6. – С. 164-169.
8. Колесников А.А. и др. Использование технологий машинного обучения при решении геоинформационных задач // ИнтерКарто. ИнтерГис. – 2018. – Т. 24, № 2. – С. 371-384.
9. Синютин С.А., Синютин Е.С., Ярцев А.В. Исследование устойчивости модели машинного обучения для обработки сигнала прибора ориентации по Земле // Математическое моделирование. – 2023. – Т. 35, № 6. – С. 3-13.

10. Булат И.В. и др. Современное состояние методов машинного обучения в приложениях обработки одномерных сигналов // *Электроника, фотоника и киберфизические системы*. – 2022. – Т. 2, № 3. – С. 86-95.
11. Иванов Д.В. и др. Новые возможности систем широкополосной когнитивной связи, работающих в ионосферных КВ-радиоканалах с внутримодовой дисперсией // *Радиотехника*. – 2022. – Т. 86, № 11. – С. 162-177.
12. Конкин Н.А. Методика и алгоритм определения периодов оперативного прогнозирования динамики максимально применимых частот КВ-связи на основе алгоритма машинного обучения XGBoost // *Вестник Поволжского государственного технологического университета. Серия: радиотехнические и инфокоммуникационные системы*. – 2022. – № 3. – С. 6-16.
13. Иванов Д.В. и др. Обеспечение предельной широкополосности систем когнитивной наземной и трасионосферной радиосвязи, работающих в условиях дисперсионных искажений // *Распространение радиоволн*. – 2023. – С. 5-13.
14. Казанцева А.А. Применение методов глубокого машинного обучения для прогнозирования доступности радиоканалов КВ-связи // *Сб. докладов I Всероссийской молодежной научной школы-конференции*. – 2024. – С. 107-110.
15. Кириллов А.С. Алгоритмы демодуляции для канала связи Ваттерсона с известными параметрами // *Радиотехника*. – 2025. – Т. 89, № 4. – С. 43-50.
16. Kirillov A.S. Machine Learning Algorithms for Signal Demodulation and Determination of HF Communication Channel Parameters // *IEEE Radiation and Scattering of Electromagnetic Waves (RSEMW)*. – 2023. – P. 268-271.
17. Кириллов А.С. Определение параметров модели Ваттерсона с помощью адаптивных фильтров // *Радиотехника*. – 2024. – № 10. – С. 5-13.
18. Кириллов А.С. Алгоритмы машинного обучения прием сигнала цифровых радиолиний // *Радиолокация и радиосвязь*. – 2022. – № 15. – С. 265.
19. Recommendation ITU-R F.1487, Testing of HF modems with bandwidths of up to about 12 kHz using ionospheric channel simulators. – 2000.
20. Recommendation ITU-R F.520, Use of high frequency ionospheric channel simulators. – 1992.

REFERENCES

1. Watterson C.C., Juroshek J.R., Bensema W.D. Experimental confirmation of an HF channel model, *IEEE(R) Trans. commun. Technol.*, 1970, No. Dec. 6, Vol. COM-18, pp. 792-803.
2. O'shea T., Hoydis J. An introduction to deep learning for the physical layer, *IEEE Transactions on Cognitive Communications and Networking*, 2017, Vol. 3, No. 4, pp. 563-575.
3. Song M., Song X., Qin K. Signal Detection and Demodulation Algorithm Based on Deep Learning in Communication Network, *2024 3rd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS)*, IEEE, 2024, pp. 461-466.
4. Fang L., Wu L. Deep learning detection method for signal demodulation in short range multipath channel, *2017 IEEE 2nd International Conference on Opto-Electronic Information Processing (ICOIP)*, IEEE, 2017, pp. 16-20.
5. Erokhin S.D., Chadov T.A., Zhuravlev A.P. Osobennosti formirovaniya obuchayushchey i testovoy vyborok dlya algoritmov mashinnogo obucheniya, ispol'zuemykh pri optimizatsii raboty priemnykh ustroystv [Features of the formation of training and test samples for machine learning algorithms used in optimizing the operation of receiving devices], *DSPA: Voprosy primeneniya tsifrovoy obrabotki signalov* [DSPA: Application Issues of Digital Signal Processing], 2020, Vol. 10, No. 1, pp. 9-14.
6. Malygin I.V. i dr. Primenenie metodov mashinnogo obucheniya dlya klassifikatsii radiosignalov [Application of machine learning methods for classification of radio signals], *Tr. MAI* [Proceedings of MAI], 2017, No. 96, pp. 15.
7. Chirkov O.N., Pirogov A.A. Primenenie algoritmov mashinnogo obucheniya v zadache otsenki besprovodnogo kanala svyazi s OFDM [Application of machine learning algorithms in the problem of assessing a wireless communication channel with OFDM], *Vestnik Voronezhskogo gosudarstvennogo tekhnicheskogo universiteta* [Bulletin of the Voronezh State Technical University], 2023, Vol. 19, No. 6, pp. 164-169.
8. Kolesnikov A.A. i dr. Ispol'zovanie tekhnologiy mashinnogo obucheniya pri reshenii geoinformatsionnykh zadach [Using machine learning technologies in solving geoinformation problems], *InterKarto. InterGis* [InterCarto. InterGis], 2018, Vol. 24, No. 2, pp. 371-384.
9. Sinyutin S.A., Sinyutin E.S., Yartsev A.V. Issledovanie ustoychivosti modeli mashinnogo obucheniya dlya obrabotki signala pribora orientatsii po Zemle [Study of the stability of a machine learning model for processing the signal of an Earth orientation device], *Matematicheskoe modelirovanie* [Mathematical Modeling], 2023, Vol. 35, No. 6, pp. 3-13.

10. Bulat I.V. i dr. Sovremennoe sostoyanie metodov mashinnogo obucheniya v prilozheniyakh obrabotki odnomernykh signalov [Current state of machine learning methods in one-dimensional signal processing applications], *Elektronika, fotonika i kiberfizicheskie sistemy* [Electronics, Photonics and Cyber-Physical Systems], 2022, Vol. 2, No. 3, pp. 86-95.
11. Ivanov D.V. i dr. Novye vozmozhnosti sistem shirokopolosnoy kognitivnoy svyazi, rabotayushchikh v ionosfernykh KV-radiokanalakh s vnutrimodovoy dispersiey [New capabilities of broadband cognitive communication systems operating in ionospheric HF radio channels with intramode dispersion], *Radiotekhnika* [Radio Engineering], 2022, Vol. 86, No. 11, pp. 162-177.
12. Konkin N.A. Metodika i algoritm opredeleniya periodov operativnogo prognozirovaniya dinamiki maksimal'no primenimykh chastot KV-svyazi na osnove algoritma mashinnogo obucheniya XGBoost [Methodology and algorithm for determining the periods of operational forecasting of the dynamics of the maximum applicable frequencies of HF communication based on the XGBoost machine learning algorithm], *Vestnik Povolzhskogo gosudarstvennogo tekhnologicheskogo universiteta. Seriya: radiotekhnicheskie i infokommunikatsionnye sistemy* [Bulletin of the Volga Region State Technological University. Series: Radio Engineering and Infocommunication Systems], 2022, No. 3, pp. 6-16.
13. Ivanov D.V. i dr. Obespechenie predel'noy shirokopolosnosti sistem kognitivnoy nazemnoy i trasionosfernoy radiosvyazi, rabotayushchikh v usloviyakh dispersionnykh iskazheniy [Ensuring the maximum bandwidth of cognitive terrestrial and transionospheric radio communication systems operating under conditions of dispersion distortions], *Rasprostraneniye radiovoln* [Radio Wave Propagation], 2023, pp. 5-13.
14. Kazantseva A.A. Primeneniye metodov glubokogo mashinnogo obucheniya dlya prognozirovaniya dostupnosti radiokanalov KV-svyazi [Application of deep machine learning methods for predicting the availability of HF radio channels], *Sb. dokladov I Vserossiyskoy molodezhnoy nauchnoy shkoly-konferentsii* [Collection of reports of the 1st All-Russian Youth Scientific School-Conference], 2024, pp. 107-110.
15. Kirillov A.S. Algoritmy demodulyatsii dlya kanala svyazi Vattersona s izvestnymi parametrami [Demodulation algorithms for the Watterson communication channel with known parameters], *Radiotekhnika* [Radio Engineering], 2025, Vol. 89, No. 4, pp. 43-50.
16. Kirillov A.S. Machine Learning Algorithms for Signal Demodulation and Determination of HF Communication Channel Parameters, *IEEE Radiation and Scattering of Electromagnetic Waves (RSEMW)*, 2023, pp. 268-271.
17. Kirillov A.S. Opredeleniye parametrov modeli Vattersona s pomoshch'yu adaptivnykh fil'trov [Determining the parameters of the Watterson model using adaptive filters], *Radiotekhnika* [Radio Engineering], 2024, No. 10, pp. 5-13.
18. Kirillov A.S. Algoritmy mashinnogo obucheniya priem signala tsifrovyykh radiolinii [Machine learning algorithms for receiving digital radio lines], *Radiolokatsiya i radiosvyaz'* [Radar and Radio Communications], 2022, No. 15, pp. 265.
19. Recommendation ITU-R F.1487, Testing of HF modems with bandwidths of up to about 12 kHz using ionospheric channel simulators, 2000.
20. Recommendation ITU-R F.520, Use of high frequency ionospheric channel simulators, 1992.

Кириллов Андрей Сергеевич – МФТИ (Национальный исследовательский университет); e-mail: Andrey.kir1997@yandex.ru; г. Долгопрудный, Россия; тел.: +79161497179.

Kirillov Andrey Sergeevich – Moscow Institute of Physics and Technology (National Research University); e-mail: Andrey.kir1997@yandex.ru; Dolgoprudny, Russia; phone: +79161497179.

УДК 004.93

DOI 10.18522/2311-3103-2026-3-105-113

А.Е. Колоденкова, М.О. Бочкарев

КОМПЛЕКСНЫЙ ПОДХОД К РАСПОЗНАВАНИЮ НАРУШИТЕЛЯ ПО ВИДЕОИЗОБРАЖЕНИЯМ

Распознавание нарушителей в условиях неконтролируемой среды является важнейшей функцией систем контроля безопасности (СКБ), основанных на биометрии и обеспечивающих защиту на объектах с массовым скоплением людей. Повысить точность подобных систем возможно за счет объединения нескольких различных биометрических признаков, полученных по видеоизображениям. Однако при работе с видеоизображениями возникает ряд проблем, связанных с изменением точки обзора, контрастности, освещения, окклюзией, посторонних объектов на заднем плане, с выбором уровня объединения биометрических признаков. Для решения данной проблемы предложен комплексный подход к распознаванию нарушителя, основанный на предварительной обработке видеоизображений, а также интеграции двух сверточных нейронных сетей (СНС), теории Демпстера-Шеффера, метода случайного леса для