

В.А. Деркачев, В.В. Бахчевников, А.Н. Бакуменко**КЛАССИФИКАТОР БПЛА МУЛЬТИРОТОРНОГО ТИПА**

Рассматривается классификатор радиолокационных сигналов, отраженных от беспилотных летательных аппаратов (БПЛА), основанный на нейронных сетях. В предложенном классификаторе для формирования обучающих данных используется модель рассеяния радиолокационных сигналов от БПЛА. В последнее время запрос на классификацию БПЛА достаточно высок ввиду значительного увеличения количества моделей и объема продаж данных устройств. Увеличение вычислительной мощности процессоров и развитие теории нейронных сетей позволяет создать новые виды классификаторов. При использовании моделей возможно создание набора обучающих данных приемлемого для обучения нейронной сети классификатора. Сверточная нейронная сеть классификатора обучается с применением радиолокационных изображений, полученных с применением предложенной модели рассеяния радиолокационных сигналов от БПЛА. Получаемые радиолокационные изображения моделируются с учетом углов ориентации БПЛА относительно нормальной системы координат БПЛА, скорости полета, различных параметров винтов моделируемого БПЛА. Для формирования обучающих данных помимо сигнальной конструкции добавляется белый шум определенной конфигурации, который помогает увеличить разнообразие обучающих выборок для улучшения обучающей способности сверточной нейронной сети. Применение данных, полученных с помощью модели для обучения нейронной сети обусловлено необходимостью использования большого числа обучающих выборок с различными параметрами движения БПЛА, такими как высота, скорость, направление, ориентация в пространстве, а также большим разнообразием возможных конфигураций беспилотных летательных аппаратов: трикоптер (три винта), квадрокоптер (четыре винта), гексакоптер (шесть винтов) или октокоптер (восемь винтов). что усложняет применение экспериментальных данных для создания классификаторов данного типа.

Классификатор; беспилотный летательный аппарат; радиолокационное изображение; математическая модель; нейронная сеть; БПЛА.

V.A. Derkachev, V.V. Bakhchevnikov, A.N. Bakumenko**MULTI-ROTOR UAV CLASSIFIER**

This article discusses a classifier of radar signals reflected from unmanned aerial vehicles (UAVs), based on neural networks. In the proposed classifier, for the formation of training data, a model of scattering of radar signals from UAVs is used. Recently, the demand for UAV classification has been quite high due to a significant increase in the number of models and sales of these devices. Increasing the computing power of processors and the development of the theory of neural networks allows you to create new types of classifiers. When using models, it is possible to create a set of training data that is acceptable for training a classifier neural network. The convolutional neural network of the classifier is trained using radar images obtained using the proposed model of scattering of radar signals from UAVs. The resulting radar images are modeled taking into account the UAV orientation angles relative to the UAV normal coordinate system, flight speed, and various propeller parameters of the simulated UAV. To form training data, in addition to the signal structure, white noise of a certain configuration is added, which helps to increase the diversity of training samples to improve the learning ability of the convolutional neural network. The use of data obtained using the model for training a neural network is due to the need to use a large number of training samples with various UAV movement parameters, such as height, speed, direction, orientation in space, as well as a wide variety of possible configurations of unmanned aerial vehicles: tricopter (three propellers), quadcopter (four propellers), hexacopter (six propellers), or octocopter (eight propellers). which complicates the use of experimental data to create classifiers of this type.

Classifier; unmanned aerial vehicle; radar image; mathematical model; neural network; UAV.

Введение. При разработке классификатора беспилотных летательных аппаратов с применением радиолокационных средств обычно применяется разделение обработки данных на два этапа: предварительная обработка данных с приведением к необходимому формату отображения и, собственно, сама классификация. Одной из основных проблем классификаторов является сложность выделения признаков, требуемых для устойчивой классификации объектов по определенным классам. Формирование радиолокационных изображений, поступающих в классифицирующую часть системы, требует определенной предварительной подготовки данных. Для решения задачи классификации необходимо определиться с видом отображения информации. Полученные после обработки радиолокационные изображения должны сохранить микродоплеровскую структуру, характеризующую параметры вращения лопастей беспилотного летательного аппарата во времени.

Одним из самых популярных методов анализа является выделение микродоплеровской сигнатуры (MDS), получаемой в следствие вращения лопастей БПЛА с большой частотой [1–5]. Данная методика является двухэтапной: преобразования полученных сигналов с применением средств частотного-временного анализа и построения представления сигнала, пригодного для дальнейшего извлечения данных. Для предварительной подготовки принимаемых радиолокационных сигналов зачастую используют метод оконного преобразования Фурье (STFT) [1, 6–9]. Применение данного метода позволяет получить изображения только низкого разрешения. Использование таких методов как MUSIC [10], итеративного адаптивного подхода (IAA) [11], и сглаженного преобразования Вигнера-Вилля (SPWVD) [12], может позволить достичь лучших результатов в плане разрешения на итоговом радиолокационном изображении. Применение предложенных методов может быть затруднено в реальных устройствах классификации ввиду большой вычислительной сложности. В результате анализа было получено решение использовать в качестве типа обработки оконное преобразование Фурье с дальнейшей генерацией дальностно-скоростного портрета наблюдаемого объекта.

Полученные в результате обработки полученного сигнала радиолокационные изображения можно использовать для классификации с применением статистических или нейронных методов. Одним из примеров классических методов является корреляционный [13]. Помимо данной методики возможно применение оптимальных байесовских классификаторов [14]. Использование вышеперечисленных методов является сложной задачей из-за трудоемкости выделения отдельных признаков в классифицируемых данных, что достаточно трудозатратно, особенно при условии сложной структуры данных, а следовательно, с большим количеством признаков. Кроме сложности в выделении признаков в классических статистических методах классификации возникают трудности с малой скоростью изменения параметров под конкретную задачу. В последнее время набирает популярность применение нейронных сетей в задачах классификации радиолокационных данных. Прогресс в развитии сверточных нейронных сетей за последние годы совместно с кратным увеличением мощностей вычислителей дал возможность формировать и использовать достаточно сложные нейросетевые структуры. Возникла возможность создания классификаторов основанных на нейронных сетях для обработки данных с радиолокационных с минимальными задержками или даже в режиме реального времени.

Использование нейросетевого классификатора приводит к необходимости в большом объеме данных для обучения нейронной сети, для чего требуется создание модели генерирующей радиолокационные изображения требуемой конфигурации БПЛА.

Совместное использование предложенной модели формирования радиолокационного изображения и нейросетевой архитектуры позволяет создать классификатор БПЛА высокой точности с большой гибкостью подстройки под решаемые задачи.

Постановка задачи. Рассматриваемая задача заключается в создании классификатора радиолокационных сигналов отраженных БПЛА различной конфигурации. Ее решение выполняется в два этапа: 1) разработка алгоритма формирования радиолокационных изображений; 2) проектирование алгоритма нейросетевого классификатора БПЛА различной конфигурации, обладающего требуемыми параметрами, для обучения которого применяются радиолокационные изображения, формируемые с использованием алгоритма полученного в первом этапе. Предлагаемый подход позволит решить следующие проблемы: 1) создание большой обучающей выборки под заданные параметры РЛС без большого объема натурных замеров; 2) формирование гибкого алгоритма классификатора под заданные параметры радиолокационных изображений.

Описание модели рассеяния сигнала от бпла. Алгоритм работы модели рассеяния радиолокационного сигнала показан на рис. 1. В начале предполагается задание параметров РЛС и БПЛА. Затем осуществляется создание первичного радиолокационного сигнала.



Рис. 1. Алгоритм модели рассеяния сигнала

Далее производится вычисление значений отраженных сигналов от БПЛА, данный этап заключается в выполнении ряда следующих операций:

- ◆ установка значений координат ротора и лопастей в системе координат P_3 (для каждого ротора по отдельности);
- ◆ перенос точек, описывающих лопасти и ротор, из системы координат P_3 в P_2 (с центром в центральной точке БПЛА);
- ◆ перенос точек, описывающих лопасти и ротор, из системы координат P_2 в P_1 (с учетом углов ориентации БПЛА);
- ◆ перенос точек, описывающих лопасти и ротор, из системы координат P_1 в P (с центром в точке с координатами РЛС);

- ◆ нахождение дальностей от лопастей и роторов БПЛА до РЛС;
- ◆ вычисление углов φ между плоскостями вращения роторов двигателей и направлением на РЛС;
- ◆ вычисление углов Θ между нормальными лопастей и направлением на РЛС;
- ◆ получение результирующего отклика на РЛ сигнал БПЛА [15].

Затем для экономии вычислительных ресурсов производится децимация отсчетов. Вычисленные отсчеты радиолокационного сигнала применяются для получения дальностно-скоростного портрета (ДСП) путем осуществления внутриимпульсного БПФ, а затем применением межпериодного БПФ.

Нейронная сеть классификатора. Одной из проблем создания классификатора является выбор архитектуры нейронной сети. Для разработки классификаторов применяют несколько типов архитектур такие как: глубокие нейронные сети [16, 17], сети глубокого доверия [18], рекуррентные нейронные сети с долгой краткосрочной памятью [19], сети на основе многослойного перцептрона [20]. Наибольшего распространения в обработке РЛ данных получили сверточные нейронные сети. Для данной работы применена сверточная архитектура.

На рис. 2 показана применяемая в работе архитектура нейронной сети. Входной слой имеет размерность $1 \times 128 \times 128$ (1 – вид цветового пространства, что значит использование градаций серого, 128 – число точек по вертикали, 128 – число точек по горизонтали) на рисунке обозначен как Input. Conv_ReLU – слой свертки с применением функции ReLU (rectified linear unit – «линейный выпрямитель»), размерность ядра применяемых слоев в начале архитектуры составляет 7×7 и 5×5 , а к концу архитектуры уменьшается до 3×3 , что необходимо для правильного выделения признаков из радиолокационного изображения. Выходная размерность данных слоев обозначена следующим образом: $A \times H \times W$, где A – число ядер свертки, H – высота изображения, W – ширина изображения. Dropout – слой исключения, необходимый для регуляризации, что позволяет улучшить обобщающую способность нейронной сети. MaxPool – слой субдискретизации осуществляющий уменьшение размерности слоев (обобщение). Full_Connected – полносвязные слои, а Output – выходной слой.




Рис. 2. Архитектура нейросетевого классификатора

Моделирование рассеяния сигнала от БПЛА. Параметры моделирования взяты в соответствии реальными данными РЛС миллиметрового диапазона TI IWR1642. В следствии отсутствия экспериментальных данных показана валидация модели путем произведения моделирования одиночного ротора с лопастями большой длины и вращающегося с очень малой скоростью. Использование данных допущений позволяет обнаружить отклики, соответствующие каждой из лопастей на сечении дальностно-скоростного портрета в различных элементах разрешения.

В табл. 1 продемонстрированы основные параметры моделирования.

В табл. 2 показаны основные параметры БПЛА в модели, используемые для валидации. Параметры модельного БПЛА подобраны таким образом, чтобы показать работоспособность модели.

Таблица 1

Параметр	Величина
Несущая частота	77 ГГц
Крутизна ЛЧМ	29,982 МГц/мкс
Ширина спектра сигнала (используемая)	767,54 МГц
Частота дискретизации ВЧ	1,6 ГГц
Число периодов ЛЧМ импульсов	128
Длительность ЛЧМ импульса	60 мкс
Период ЛЧМ импульсов	160 мкс
Частота дискретизации АЦП	10 МГц
Число отсчетов АЦП за один период	256
Время моделирования	20,3 мс

Таблица 2

Параметр	Величина
Число лопастей на роторе	2
Число роторов	1
Размеры лопасти	2 м
Радиус оси ротора	0,0025 м
Частота вращения лопасти	0,0796 Гц

На рис. 3 представлен результат моделирования в виде сечения дальностно-скоростного портрета, который является результатом моделирования одиночного ротора с лопастями большого размаха и очень малой скорости вращения (табл. 1, 2).

Радиальные скорости оконечной части лопастей при установке начального угла поворота лопасти 20^0 равны 1 м/с и минус 0,8 м/с, что совпадает с результатами показанными на сечении ДСП по уровню минус 20 дБ.

Помимо скоростных характеристик лопастей на сечении ДСП можно увидеть попадание откликов оконечной части лопастей в разные элементы по дальности (9,38 м и 10,9 м для каждой из лопастей, при условии нахождения ротора на расстоянии 10 м), что подтверждает правильность формирования радиолокационных изображений для заданных параметров сигнала и цели.




Рис. 3. Сечение ДСП одиночного винта

Формирование обучающих данных. Для тестирования нейронной сети классификатора предполагается использование двух моделей БПЛА: Xiaomi Mi Drone Mini (рис. 4,а) и DJI Mavic2 PRO (рис. 4,б). Основные характеристики Xiaomi Mi Drone Mini представлены в табл. 3, а DJI Mavic2 PRO представлены в табл. 4.



Рис. 4. Моделируемые БПЛА

Таблица 3

Параметр	Величина
Число лопастей на роторе	2
Число роторов	4
Длина лопасти	0,038 м
Радиус оси ротора	0,0025 м
Ширина лопасти	0,005 м
Частота вращения лопастей	± 100 Гц
Координаты ротора 1	-0.041; 0.041 м
Координаты ротора 2	0.041; 0.041 м
Координаты ротора 3	0.041; -0.041 м
Координаты ротора 4	-0.041; -0.041 м

Таблица 4

Параметр	Величина
Число лопастей на роторе	2
Число роторов	4
Длина лопасти	0,107 м
Радиус оси ротора	0,011 м
Ширина лопасти	0,022 м
Частота вращения лопастей	± 100 Гц
Координаты ротора 1	-0.1285; 0.109 м
Координаты ротора 2	0.1285; 0.109 м
Координаты ротора 3	0.1524; -0.109 м
Координаты ротора 4	-0.1524; -0.109 м

Получаемые радиолокационные изображения имеют разрешение 128x128 точек. Для обучения генерируется 1000 изображений для каждого БПЛА с различными параметрами углов ориентации БПЛА. Помимо изображений с БПЛА сформированы изображения только с подстилающей поверхностью. Затем добавляя шум на изображение с различными значениями параметров нормального распределения: матожидание от 56,99 до 79,66 и среднеквадратического отклонения от 11,17 до 12,3. В результате имеется по 10000 изображений каждого класса. Примеры полученных РЛИ представлены для Xiaomi Mi Drone Mini на рис. 5,а, для DJI Mavic2 PRO на рис. 5,б, для подстилающей поверхности без БПЛА рис. 5,в.

Обучение нейронной сети. Обучение НС производилось в Tensorflow версии 2.11 установленной в системе Ubuntu 20.04 LTS. Моделируемые РЛИ, полученные в предыдущем разделе, были разделены на 3 выборки – обучающую (70% изображений), тестовую (по 50 изображений каждого класса) и валидационную (оставшиеся изображения). Графики точности нейронной сети и функции потерь в процессе обучения показаны на рис. 6.




Рис. 5. Моделируемые РЛИ




Рис. 6. Графики процесса обучения НС

Проверка на тестовых данных, состоящих из 50 изображений класса Xiaomi Mi Drone Mini, 50 изображений DJI Mavic2 PRO и 50 изображений без БПЛА, показана на рис. 7. НС допускает 1 ошибку на 150 тестовых изображений.




Рис. 7. Работа НС на тестовых данных

По результатам обучения достигнута точность тренировочная 0,9998, валидационная 0,9999, тестовая 0,9933.

Выводы. Предложенный классификатор мультироторных БПЛА с применением нейронных сетей позволяет осуществлять классификацию объектов различной конфигурации. Применение модели рассеяния РЛ сигналов от БПЛА позволяет осуществлять генерацию обучающих данных для нейронной сети классификатора с различными параметрами сигнала РЛС, характеристиками БПЛА и текущими параметрами полета данного аппарата. Использование модели рассеяния позволяет относительно быстро формировать большие наборы данных, что является одним из самых трудоемких и дорогих этапов создания классификаторов. Применение в структуре классификатора нейронной сети сверточного типа, а также правильно сформированных обучающих данных позволяет получить стабильные результаты классификации различных моделей мультироторных БПЛА. В результате численного эксперимента получена точность классификации 0,9933 по тестовым данным. Полученная точность превышает точность классификации нейросетевых классификаторов БПЛА из работы [16] и [17], которая составила 0,9815 и 0,9654, соответственно.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Molchanov P. et al. Classification of small UAVs and birds by micro-Doppler signatures // International Journal of Microwave and Wireless Technologies. – 2014. – Vol. 6, No. 3-4. – P. 435-444.
2. De Wit J.J.M., Harmanny R.I.A., Molchanov P. Radar micro-Doppler feature extraction using the singular value decomposition // 2014 International Radar Conference. – IEEE, 2014. – P. 1-6.
3. Zhang P. et al. Classification of drones based on micro-Doppler signatures with dual-band radar sensors // 2017 Progress in Electromagnetics Research Symposium-Fall (PIERS-FALL). – IEEE, 2017. – P. 638-643.
4. Kim B.K., Kang H.S., Park S.O. Drone classification using convolutional neural networks with merged Doppler images // IEEE Geoscience and Remote Sensing Letters. – 2016. – Vol. 14, No. 1. – P. 38-42.
5. Oh B.S. et al. An EMD-based micro-Doppler signature analysis for mini-UAV blade flash reconstruction // 2017 22nd International Conference on Digital Signal Processing (DSP). – IEEE, 2017. – P. 1-5.

6. Stankovic L., Djurovic I., Thayaparan T. Separation of target rigid body and micro-Doppler effects in ISAR imaging // IEEE Transactions on Aerospace and Electronic Systems. – 2006. – Vol. 42, No. 4. – P. 1496-1506.
7. Fioranelli F., et al. Classification of loaded/unloaded micro-drones using multistatic radar // Electronics Letters. – 2015. – Vol. 51, No. 22. – P. 1813-1815.
8. Stankovic L., Thayaparan T., Dakovic M. Signal decomposition by using the S-method with application to the analysis of HF radar signals in sea-clutter // IEEE Transactions on Signal Processing. – 2006. – Vol. 54, No. 11. – P. 4332-4342.
9. Stankovic L., Daković M., Thayaparan T. Time-frequency signal analysis with applications. – Artech house, 2014.
10. Schmidt R. Multiple emitter location and signal parameter estimation // IEEE transactions on antennas and propagation. – 1986. – Vol. 34, No. 3. – P. 276-280.
11. Sun H., et al. Improving the Doppler resolution of ground-based surveillance radar for drone detection // IEEE Transactions on Aerospace and Electronic Systems. – 2019. – Vol. 55, No. 6. – P. 3667-3673.
12. Tan R., et al. Improved micro-Doppler features extraction using smoothed-pseudo Wigner-Ville distribution // 2016 IEEE Region 10 Conference (TENCON). – IEEE, 2016. – P. 730-733.
13. Гонсалес Р., Вудс Р. Цифровая обработка изображений: пер. с англ. – М.: Издательский дом Техносфера, 2005. – 1073 с.
14. Anderson T.W., Goodman L.A. Statistical inference about Markov chains // The Annals of Mathematical Statistics. – 1957. – P. 89-110.
15. Деркачев В.А. Модель рассеяния радиолокационных сигналов от беспилотных летательных аппаратов // Известия ЮФУ. Технические науки. – 2021. – № 2 (219). – С. 120-129.
16. Martinez J., et al. Convolutional neural network assisted detection and localization of UAVs with a narrowband multi-site radar // 2018 IEEE MTT-S International Conference on Microwave for Intelligent Mobility (ICMIM). – IEEE, 2018. – P. 1-4.
17. Wang L., Tang J., Liao Q. A study on radar target detection based on deep neural networks // IEEE Sensors Letters. – 2019. – Vol. 3, No. 3. – P. 1-4.
18. Mendis G.J., et al. Deep learning based doppler radar for micro UAS detection and classification // MILCOM 2016-2016 IEEE Military Communications Conference. – IEEE, 2016. – P. 924-929.
19. Stankovic L., Djurovic I., Thayaparan T. Separation of target rigid body and micro-Doppler effects in ISAR imaging // IEEE Transactions on Aerospace and Electronic Systems. – 2006. – Vol. 42, No. 4. – P. 1496-1506.
20. Regev N., Yoffe I., Wulich D. Classification of single and multi propelled miniature drones using multilayer perceptron artificial neural network. – 2017.

REFERENCES

1. Molchanov P. et al. Classification of small UAVs and birds by micro-Doppler signatures, *International Journal of Microwave and Wireless Technologies*, 2014, Vol. 6, No. 3-4, pp. 435-444.
2. De Wit J.J.M., Harmanny R.I.A., Molchanov P. Radar micro-Doppler feature extraction using the singular value decomposition, *2014 International Radar Conference*. IEEE, 2014, pp. 1-6.
3. Zhang P. et al. Classification of drones based on micro-Doppler signatures with dual-band radar sensors, *2017 Progress in Electromagnetics Research Symposium-Fall (PIERS-FALL)*. IEEE, 2017, pp. 638-643.
4. Kim B.K., Kang H.S., Park S.O. Drone classification using convolutional neural networks with merged Doppler images, *IEEE Geoscience and Remote Sensing Letters*, 2016, Vol. 14, No. 1, pp. 38-42.
5. Oh B.S. et al. An EMD-based micro-Doppler signature analysis for mini-UAV blade flash reconstruction, *2017 22nd International Conference on Digital Signal Processing (DSP)*. IEEE, 2017, pp. 1-5.
6. Stankovic L., Djurovic I., Thayaparan T. Separation of target rigid body and micro-Doppler effects in ISAR imaging, *IEEE Transactions on Aerospace and Electronic Systems*, 2006, Vol. 42, No. 4, pp. 1496-1506.
7. Fioranelli F., et al. Classification of loaded/unloaded micro-drones using multistatic radar, *Electronics Letters*, 2015, Vol. 51, No. 22, pp. 1813-1815.

8. Stankovic L., Thayaparan T., Dakovic M. Signal decomposition by using the S-method with application to the analysis of HF radar signals in sea-clutter, *IEEE Transactions on Signal Processing*, 2006, Vol. 54, No. 11, pp. 4332-4342.
9. Stankovic L., Daković M., Thayaparan T. Time-frequency signal analysis with applications. Artech house, 2014.
10. Schmidt R. Multiple emitter location and signal parameter estimation, *IEEE transactions on antennas and propagation*, 1986, Vol. 34, No. 3, pp. 276-280.
11. Sun H., et al. Improving the Doppler resolution of ground-based surveillance radar for drone detection, *IEEE Transactions on Aerospace and Electronic Systems*, 2019, Vol. 55, No. 6, pp. 3667-3673.
12. Tan R., et al. Improved micro-Doppler features extraction using smoothed-pseudo Wigner-Ville distribution, *2016 IEEE Region 10 Conference (TENCON)*. IEEE, 2016, pp. 730-733.
13. Gonzalez R., Vuds R. Tsifrovaya obrabotka izobrazheniy [Digital image processing]: transl. from engl. Moscow: Izdatel'skiy dom Tekhnosfera, 2005, 1073 p.
14. Anderson T.W., Goodman L.A. Statistical inference about Markov chains, *The Annals of Mathematical Statistics*, 1957, pp. 89-110.
15. Derkachev V.A. Model' rasseyaniya radiolokatsionnykh signalov ot bespilotnykh letatel'nykh apparatov [The scattering model of radar signals from unmanned aerial vehicles], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2021, No. 2 (219), pp. 120-129.
16. Martinez J., et al. Convolutional neural network assisted detection and localization of UAVs with a narrowband multi-site radar, *2018 IEEE MTT-S International Conference on Microwave for Intelligent Mobility (ICMIM)*. IEEE, 2018, pp. 1-4.
17. Wang L., Tang J., Liao Q. A study on radar target detection based on deep neural networks, *IEEE Sensors Letters*, 2019, Vol. 3, No. 3, pp. 1-4.
18. Mendis G.J., et al. Deep learning based doppler radar for micro UAS detection and classification, *MILCOM 2016-2016 IEEE Military Communications Conference*. IEEE, 2016, pp. 924-929.
19. Stankovic L., Djurovic I., Thayaparan T. Separation of target rigid body and micro-Doppler effects in ISAR imaging, *IEEE Transactions on Aerospace and Electronic Systems*, 2006, Vol. 42, No. 4, pp. 1496-1506.
20. Regev N., Yoffe I., Wulich D. Classification of single and multi propelled miniature drones using multilayer perceptron artificial neural network, 2017.

Статью рекомендовал к опубликованию д.т.н. Ю.А. Кравченко.

Деркачев Владимир Александрович – Южный федеральный университет; e-mail: vderkachev@sfedu.ru; г. Таганрог, Россия; тел.: +79614154733; кафедра радиотехнических и телекоммуникационных систем; ассистент.

Бахчевников Валентин Владимирович – e-mail: bahchevnikov@sfedu.ru; тел.: +79518289271; кафедра радиотехнических и телекоммуникационных систем; старший преподаватель.

Бакуменко Алексей Николаевич – e-mail: baku@sfedu.ru; тел.: +79886031853; кафедра радиотехнических и телекоммуникационных систем; ассистент.

Derkachev Vladimir Aleksandrovich – Southern Federal University; e-mail: vderkachev@sfedu.ru; Taganrog, Russia; phone +79614154733; the department of radio engineering & telecommunication systems; assistant.

Bakhchevnikov Valentin Vladimirovich – e-mail: bahchevnikov@sfedu.ru; phone: +79518289271; the department of radio engineering & telecommunication; senior lecturer.

Bakumenko Alexey Nikolaevich – e-mail: baku@sfedu.ru; phone: +79886031853; the department of radio engineering & telecommunication systems; assistant.