

Труды МАИ. 2024. № 134  
Trudy MAI, 2024, no. 134

Научная статья  
УДК 623.74.094  
URL: <https://trudymai.ru/published.php?ID=178473>

## **СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОСЕТЕВЫХ АРХИТЕКТУР В ЗАДАЧЕ ОБНАРУЖЕНИЯ И РАЗЛИЧЕНИЯ СИГНАЛОВ ЦЕЛИ И УВОДЯЩЕЙ ПОМЕХИ**

**Никита Александрович Коваль**

Московский авиационный институт (национальный исследовательский университет),  
Москва, Россия

[niki-kov@yandex.ru](mailto:niki-kov@yandex.ru)

*Аннотация.* Рассмотрено применение аппарата искусственных нейронных сетей в задаче обнаружения и разрешения сигналов цели и уводящей помехи. Показано, что данную задачу в контексте машинного обучения можно свести к задаче обработки временных последовательностей. Приведены результаты обучения и сопоставительного анализа ряда соответствующих нейросетевых архитектур.

*Ключевые слова:* уводящая помеха, радиолокационный сигнал, глубокое обучение, нейронные сети, спектр

*Для цитирования:* Коваль Н.А. Сравнительный анализ нейросетевых архитектур в задаче обнаружения и различения сигналов цели и уводящей помехи // Труды МАИ. 2024. № 134. URL: <https://trudymai.ru/published.php?ID=178473>

Original article

# COMPARATIVE ANALYSIS OF NEURAL NETWORK ARCHITECTURES IN THE TASK OF DETECTION AND IDENTIFICATION OF TARGET AND VELOCITY JAMMER SIGNALS

**Nikita A. Koval**

Moscow Aviation Institute (National Research University),

Moscow, Russia

[niki-kov@yandex.ru](mailto:niki-kov@yandex.ru)

**Abstract.** As is known, radar signals are subjected to various kinds of interference. A special place is occupied by the imitating interference to automatic tracking systems (leading-astray interference). The means for the leading-astray interference creating are capable of generating signals, which smoothly introduces false information about the target movement parameters (such as Doppler frequency or delay time), which ultimately leads to the automatic tracking failure [1-2].

Velocity leading-astray jammers (VJ) represent the greatest danger for the onboard Doppler radar stations. The jamming effect file detection and jamming and target signals distinction at the initial stage of the jammer operation, which would prevent the traction failure and ensure reliable information obtaining about the target, may be solution to the problem of the VJ counteracting. The capabilities of artificial neural networks (deep learning) are being studied in the presented article for this problem solution. The idea consists in regularities educing by the neural networks in characteristic dynamics of the signal spectrum received by the radar system under the imVJ pact of the in the process of their learning.

Temporal interrelation of the spectrums, obtained at the successive radar station operating cycles, should be accounted for the characteristic dynamics educating, which brings us explicitly to the time sequences processing task. As long as the very fact of the interference impact educating is understood as the VJ signal detection task, this can be represented in the context of machine learning in the form of the spectrum classification task (spectrum transformation of the signal received at every cycle of the radar operation into the VJ presence/absence mark). The signal frequency estimation in its turn is being reduced to determining the index number of the Doppler's filter, which in their essence are the frequency domain sampling. That is, each filter is assigned a certain frequency range of the signal being analyzed at a given time instant. Thus, this task can be represented as a spectrum regression (converting the spectrum into the number of the Doppler filter of the target signal).

The following architectures intended for the time sequences processing are being studied within the framework of this article: classical convolutional CNN network (for working with time sequences, layers of one-dimensional convolution are employed) [7]; temporary convolutional TCN network [8]; recurrent networks based on the LSTM long short-term memory layers [9]; networks based on managed recurrent GRU units [10]. Several models of each presented architecture were trained with different number of layers, size of layers, etc. To assess the trained models quality, the root of the mean square error (RMSE) for the regression problem and the F-measure (F1-score) for the classification problem were applied.

The result of the accuracy comparing of the considered architectures revealed that CNN displayed the worst result of 6.3 RMSE and 0.986 F1-score. The LSTM and GRU appeared to be the most accurate in both tasks (1.23 RMSE and 0.997 F1-score, 1.27 RMSE and 0.995 F1-score, respectively), and in the classification task, they apparently reached the limit of accuracy. TCN performed slightly worse (1.45 RMSE and 0.994 F1-score), however, the required network size to achieve results comparable to LSTM and GRU makes the use of TCN impractical.

The author recommends employing the LSTM or GRU network with two layers of 100 hidden units for regression and an LSTM with two layers of 25 hidden units for classification in the considered task. The choice between architectures is being stipulated by the required level of accuracy and hardware limitations on the counteraction algorithm being developed: the LSTM is slightly more accurate, but due to its structure, it has more trainable parameters with the same number of hidden units, which leads to the use of more memory and lower computing speed compared to GRU.

Thus, the article demonstrates that neural networks are able to solve the said problems quite accurately. In the course of the study, a comparative analysis of neural network architectures designed for processing time sequences was performed and suitable for further integration into onboard digital signal processing algorithms were identified.

The author's further intention is to study the selected architectures structures in the more complicated jamming situation.

**Keywords:** velocity jammer, radar signal, deep learning, neural networks, spectrum

**For citation:** Koval N.A. Comparative analysis of neural network architectures in the task of detection and identification of target and velocity jammer signals. *Trudy MAI*, 2024, no. 134. URL: <https://trudymai.ru/eng/published.php?ID=178473>

## Введение

Как известно, радиолокационные сигналы подвержены воздействию различного рода помех. Особое место занимают имитирующие помехи системам автоматического сопровождения (уводящие помехи). Средства создания уводящих помех способны генерировать излучения, в которые плавно вносится ложная информация о параметрах движения цели (например, доплеровской частоте или времени запаздывания), что в конечном итоге приводит к срыву автоматического сопровождения [1-2].

Зачастую время работы бортовых радиолокационных станций (РЛС) сильно ограничено по времени в сравнении с наземными РЛС. Поэтому для таких РЛС требуется не допустить срыва автоматического сопровождения цели. Для импульсно-доплеровских РЛС с сопровождением цели по доплеровской скорости, наибольшую опасность представляют уводящие помехи по скорости (УПС).

Исходя из этого, воздействие УПС на бортовые РЛС может критическим образом повлиять на достижение поставленных перед носителем бортовой РЛС задач. Решением данной проблемы противодействия УПС может стать обнаружение факта действия помехи и разрешение сигналов помехи и цели на начальном этапе работы

постановщика помех, что позволит предотвратить срыв сопровождения и обеспечить надежное получение информации о цели.

В работе [3] авторы разработали алгоритм идентификации воздействия уводящих помех, основанные на допущении, что отраженный от воздушной цели сигнал состоит из двух различных составляющих: отраженного сигнала от планера цели и от вращающихся частей компрессора низкого давления её силовой установки.

В статьях [4-6] авторы предлагают способ защиты от помех на основе случайного изменения фаз импульсов сигнала, основываясь на предположении, что постановщик помех использует технологию цифровой радиочастотной памяти [7].

В данной работе для решения задачи обнаружения и разрешения сигналов исследуются возможности аппарата искусственных нейронных сетей (глубокого обучения). Известен ряд работ, в которых исследуется применение нейронных сетей для обработки радиосигналов [8-10]. Идея данной работы состоит в выявлении нейронными сетями закономерностей в характерной динамике спектра принятого РЛС сигнала при воздействии УПС в процессе их обучения, что позволит решить поставленную задачу. Данный подход отличается возможностью противодействия помехам с нелинейными законами увода и отсутствием необходимости априорных знаний об устройстве постановщика помех, так как основан на базовых принципах воздействия помех на РЛС.

Для выявления характерной динамики необходимо учитывать временную взаимосвязь спектров, полученных на последовательных тактах работы РЛС, что явным образом приводит нас к задаче обработки временных последовательностей.

Известен ряд архитектур нейронных сетей применимых для подобных задач. Выбор наиболее подходящих для последующей интеграции в бортовые алгоритмы цифровой обработки сигналов осуществляется путем обучения и сопоставительного анализа точности и размеров различных вариантов нейронных сетей.

### **Основная часть**

Необходимо пояснить, что под задачей обнаружения сигнала УПС понимается выявление самого факта воздействия помехи. В контексте машинного обучения это можно представить в виде задачи классификации спектра (преобразование полученного на каждом такте работы РЛС спектра принимаемого сигнала в метку класса наличия/отсутствия УПС).

Под задачей различения сигналов понимается определение доплеровской частоты сигнала цели (полезной информации) при воздействии помехи (исходя из принципа воздействия УПС, следящая система сопровождает помеху). Оценка частоты сигнала цели сводится к определению порядкового номера доплеровского фильтра, которые по сути являются дискретизацией частотной области, то есть каждому фильтру ставится в соответствие определенный диапазон частот анализируемого в данный момент времени сигнала. Таким образом, эту задачу можно представить в виде регрессии спектра (преобразование спектра в номер доплеровского фильтра сигнала цели).

Выборка данных объемом 4000 примеров была получена путем имитационного моделирования процессов функционирования бортовой РЛС в среде Matlab/Simulink

в условиях воздействия УПС и разбита на обучающую и тестовую подвыборки (75% и 25% соответственно). Обучающие примеры для регрессора и классификатора

представляют собой  $\{x, y_{NF}\}$  и  $\{x, y_{UPS}\}$  соответственно, где  $x = \begin{pmatrix} x_{11} & \dots & x_{1t} \\ \vdots & \ddots & \vdots \\ x_{661} & \dots & x_{66t} \end{pmatrix}$  –

спектр сигнала продолжительностью  $t$  тактов работы РЛС,  $y_{NF} = (y_{NF}^1, \dots, y_{NF}^t)$  –

последовательность целевых значений номеров доплеровского фильтра цели,  $y_{UPS} =$

$(y_{UPS}^1, \dots, y_{UPS}^t)$  – последовательность целевых значений меток класса (признака

наличия УПС в спектре). На рисунках 1-2 представлен пример из обучающей выборки

(спектр нормирован по мощности).

В рамках данной статьи исследуются следующие архитектуры, предназначенные для обработки временных последовательностей: классическая



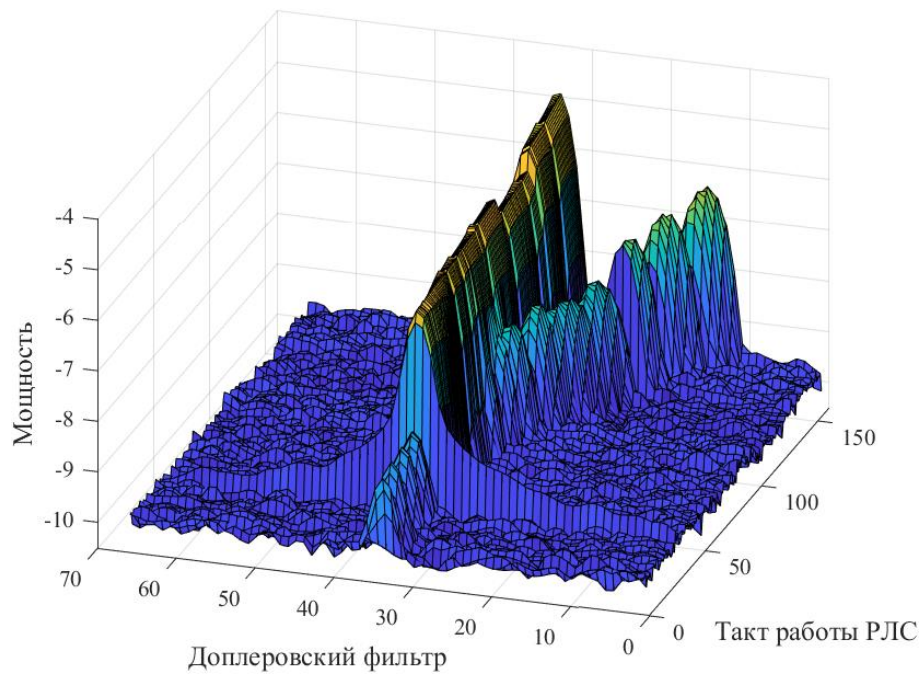


Рис. 1. Спектр принимаемого сигнала

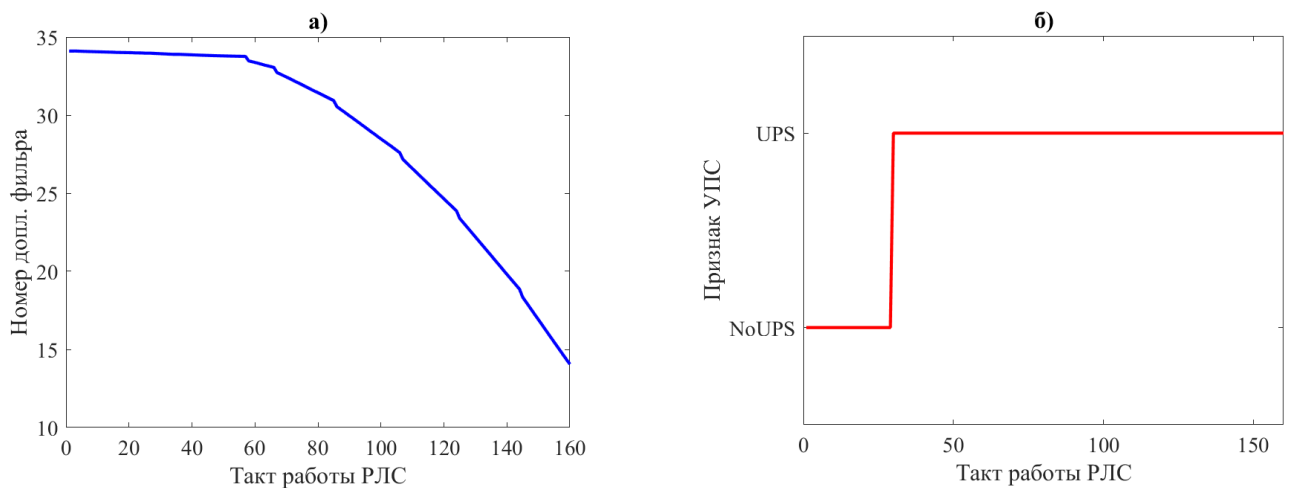


Рис. 2. Целевые значения. а) – номер фильтра; б) – метки классов

сверточная сеть CNN (для работы с временными последовательностями используются слои одномерной свёртки (1d convolutions)) [11], временная сверточная сеть TCN [12], рекуррентные сети на основе слоев долгой краткосрочной памяти LSTM [13], сети на основе управляемых рекуррентных блоков GRU [14].

Для разработки нейросетевых моделей использовалась среда Matlab с пакетом Deep Learning Toolbox. Было обучено несколько моделей каждой представленной архитектуры с 2-4 блоками (последовательно соединенных слоев свертки, пулинга и

ReLU активации) для CNN, с 2-4 остаточными блоками (residual block) для TCN. Для данных архитектур рассмотрено три варианта количества фильтров (16, 32, 64) и два варианта размера фильтра (3, 5). В случае LSTM и GRU использовались 1-2 рекуррентных слоя с тремя вариантами количества скрытых блоков (25, 50, 100). В качестве функции потерь (loss function) для задачи регрессии была выбрана среднеквадратичная ошибка (MSE), для задачи классификации – взвешенная перекрестная энтропия [15]. Обучение проводилось алгоритмом «Adam» [16] (одним из вариантов стохастического градиентного спуска – основного алгоритма обучения нейронных сетей на текущий момент [17-18]) в течении 10 эпох с применением L2 регуляризации весов [19] и ограничением градиентов [20], начальная скорость обучения - 0.01 с понижением в 10 раз каждые 3 эпохи.

На рисунке 3 представлены результаты обучения трёх наиболее точных моделей каждой архитектуры в виде зависимости точности от размеров сети (количества обучаемых параметров). Для оценки качества обученных моделей использовался корень среднеквадратичной ошибки (RMSE) для задачи регрессии и F-мера (F1-score) для задачи классификации.

На рисунке 4 представлены результаты работы нейросетевых моделей на примере из тестовой выборки. Ввиду того, что LSTM и GRU сети показали схожий результат, продемонстрирована только LSTM.




Рис. 3. Результаты обучения. а) – регрессия; б) – классификация

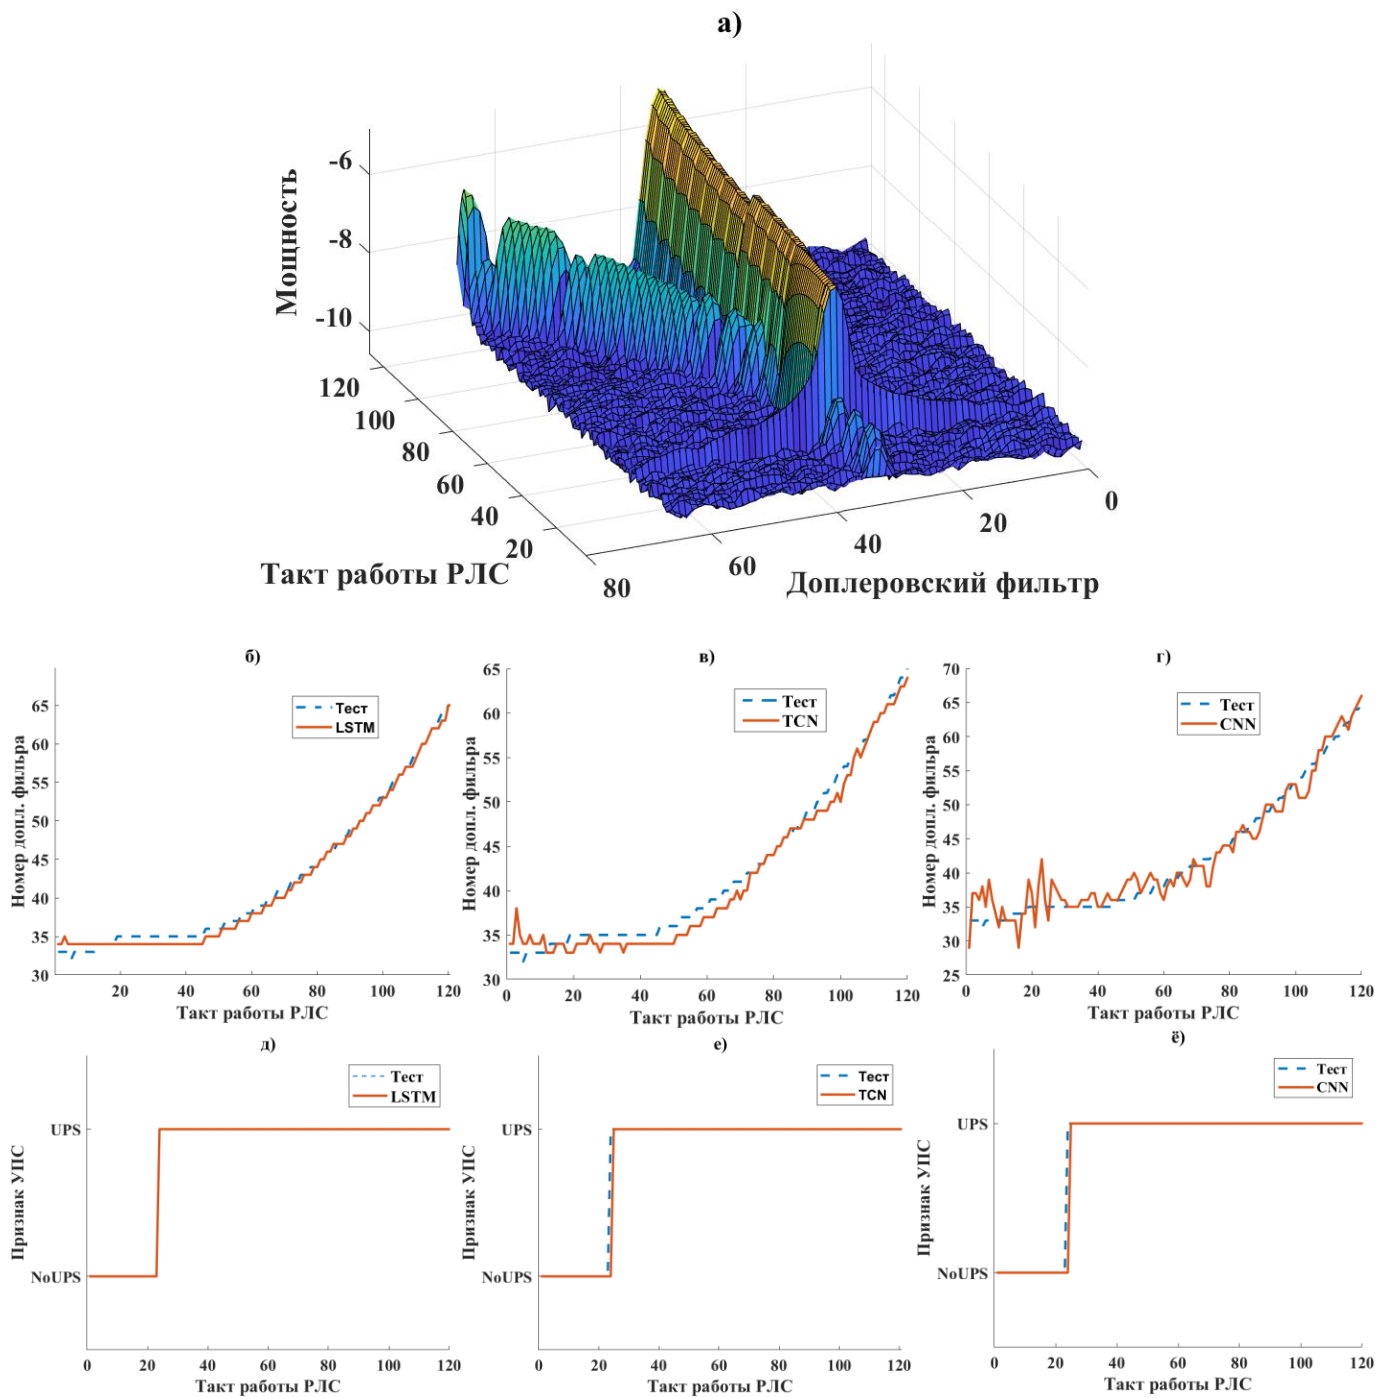


Рис. 4. Пример работы моделей. (а) – вход; (б)-(г) – сравнение выхода моделей с целевым значением номера фильтра; (д)-(ё) - сравнение выхода моделей с целевыми значениями меток классов

## **Выводы**

В результате сравнения точности рассмотренных архитектур видно, что CNN показали наихудший результат. Наиболее точными в обеих задачах оказались LSTM и GRU, причем в задаче классификации, по всей видимости, ими достигнут предел точности. Немного хуже показали себя TCN, однако необходимый размер сети для достижения результатов, сопоставимых с LSTM и GRU, делает применение TCN нецелесообразным.

В рассмотренной задаче рекомендуется использовать LSTM или GRU сеть с 2 слоями по 100 скрытых блоков для регрессии и LSTM с 2 слоями по 25 скрытых блоков для классификации. Выбор между архитектурами обуславливается требуемым уровнем точности и аппаратными ограничениями на разрабатываемый алгоритм противодействия: LSTM чуть точнее, но за счет своей структуры имеет больше обучаемых параметров при том же количестве скрытых блоков, что приводит к задействованию большего объема памяти и меньшей скорости вычислений по сравнению с GRU.

## **Заключение**

В рамках данной статьи рассмотрено применение нейронных сетей для задачи обнаружения и разрешения сигналов цели и УПС. На данных имитационного моделирования показано, что нейронные сети способны довольно точно решать подобные задачи. В ходе исследования был проведен сравнительный анализ нейросетевых архитектур, предназначенных для обработки временных

последовательностей, и выявлены подходящие для дальнейшей интеграции в бортовые алгоритмы цифровой обработки сигналов.

В дальнейшем предполагается исследовать функционирование выбранных архитектур в более сложной помеховой обстановке.

### **Список источников**

1. Леонов А.И., Фомичев К.И. Моноимпульсная радиолокация. - М.: Советское Радио, 1970. - 392 с.
2. Берикашвили В.Ш., Черепанов А.К. Радиотехнические системы извлечения и обработки информации: монография. – М.: МГТУ МИРЭА, 2011. – 272 с.
3. Богданов А.В., Закомолдин Д.В., Докучаев Я.С., Новичёнок В.А., Кочетов И.В. Алгоритм идентификации уводящих по дальности и скорости помех в импульсно-доплеровских РЛС в интересах формирования достоверных оценок дальности и скорости при сопровождении воздушной цели // Журнал Сибирского федерального университета. Техника и технологии. 2019. Т. 12. № 1. С. 30-40. DOI: [10.17516/1999-494X-0103](https://doi.org/10.17516/1999-494X-0103)
4. Xiong W., Wang X., Zhang G. Cognitive waveform design for anti-velocity deception jamming with adaptive initial phases // 2016 IEEE Radar Conference (RadarConf), Philadelphia, PA, USA, 2016, pp. 1-5. DOI: [10.1109/RADAR.2016.7485306](https://doi.org/10.1109/RADAR.2016.7485306)
5. Ya Yang, Jian Wu, Guolong Cui, Liang Li, Lingjiang Kong and Yulin Huang. Optimized phase-coded waveform design against velocity deception // 2015 IEEE Radar

- Conference (RadarCon), Arlington, VA, 2015, pp. 0400-0404. DOI: [10.1109/RADAR.2015.7131032](https://doi.org/10.1109/RADAR.2015.7131032)
6. Liu Z., Sui J., Wei Z., Li X. A Sparse-Driven Anti-Velocity Deception Jamming Strategy Based on Pulse-Doppler Radar with Random Pulse Initial Phases // Sensors, 2018, vol. 18, pp. 1249. DOI: [10.3390/s18041249](https://doi.org/10.3390/s18041249)
  7. Подстригаев А.С., Смоляков А.В. Исследование спектра сигнала при двукратном частотном преобразовании // Труды МАИ. 2020. № 114. URL: <https://trudymai.ru/published.php?ID=118984>. DOI: [10.34759/trd-2020-114-11](https://doi.org/10.34759/trd-2020-114-11)
  8. Малыгин И.В., Бельков С.А., Тарасов А.Д., Усвяцов М.Р. Применение методов машинного обучения для классификации радиосигналов // Труды МАИ. 2017. № 96. URL: <https://trudymai.ru/published.php?ID=85797>
  9. Ефимов Е.Н., Шевгунов Т.Я. Формирование оценки направления прихода сигнала с использованием искусственных нейронных сетей // Труды МАИ. 2015. № 82. URL: <https://trudymai.ru/published.php?ID=58786>
  10. Ефимов Е.Н., Шевгунов Т.Я. Разработка и исследование методики построения нейронных сетей на основе адаптивных элементов // Труды МАИ. 2012. № 51. URL: <https://trudymai.ru/published.php?ID=29159>
  11. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. - СПб.: Питер, 2018. - 480 с.
  12. Bai Shaojie, J. Zico Kolter, and Vladlen Koltun. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling // Computer Science, 2018. URL: <https://doi.org/10.48550/arXiv.1803.01271>

13. Hochreiter S., Schmidhuber J. Long short-term memory // Neural computation, 1997, vol. 9 (8), pp.1735–1780. DOI: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)
14. Cho Kyunghyun, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using RNN encoder-decoder for statistical machine translation // Computer Science, 2014. URL: <https://doi.org/10.48550/arXiv.1406.1078>
15. Bishop C.M. Pattern Recognition and Machine Learning, Springer, New York, NY, 2006.
16. Kingma Diederik, Jimmy Ba. Adam: A method for stochastic optimization // Computer Science, 2014. URL: <https://doi.org/10.48550/arXiv.1412.6980>
17. Murphy K.P. Machine Learning: A Probabilistic Perspective. The MIT Press, Cambridge, Massachusetts, 2012.
18. Pascanu R., Mikolov T., Bengio Y. On the difficulty of training recurrent neural networks // Proceedings of the 30th International Conference on Machine Learning, 2013, vol. 28 (3), pp. 1310–1318.
19. Bottou Léon, Bousquet Olivier. The Tradeoffs of Large Scale Learning // Conference: Advances in Neural Information Processing Systems 20, Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems, Vancouver, British Columbia, Canada, December 3-6, 2007.
20. Bottou Léon. Online Algorithms and Stochastic Approximations. Online Learning and Neural Networks, Cambridge University Press, Cambridge, UK, 1998.



## References

1. Leonov A.I., Fomichev K.I. *Monoimpul'snaya radiolokatsiya*. (Monopulse radiolocation), Moscow, Sovetskoe Radio, 1970, 392 p.
2. Berikashvili V.Sh., Cherepanov A.K. *Radiotekhnicheskie sistemy izvlechenii i obrabotki informatsii* (Radio engineering systems of information retrieval and processing), Moscow, MGTU MIREA, 2011, 272 p.
3. Bogdanov A.V., Zakomoldin D.V., Dokuchaev Ya.S., Novichënok V.A., Kochetov I.V. *Zhurnal Sibirskogo federal'nogo universiteta. Tekhnika i tekhnologii*, 2019, vol. 12, no. 1, pp. 30-40. DOI: [10.17516/1999-494X-0103](https://doi.org/10.17516/1999-494X-0103)
4. Xiong W., Wang X., Zhang G. Cognitive waveform design for anti-velocity deception jamming with adaptive initial phases, *2016 IEEE Radar Conference (RadarConf)*, Philadelphia, PA, USA, 2016, pp. 1-5. DOI: [10.1109/RADAR.2016.7485306](https://doi.org/10.1109/RADAR.2016.7485306)
5. Ya Yang, Jian Wu, Guolong Cui, Liang Li, Lingjiang Kong and Yulin Huang. Optimized phase-coded waveform design against velocity deception, *2015 IEEE Radar Conference (RadarCon)*, Arlington, VA, 2015, pp. 0400-0404. DOI: [10.1109/RADAR.2015.7131032](https://doi.org/10.1109/RADAR.2015.7131032)
6. Liu Z., Sui J., Wei Z., Li X. A Sparse-Driven Anti-Velocity Deception Jamming Strategy Based on Pulse-Doppler Radar with Random Pulse Initial Phases, *Sensors*, 2018, vol. 18, pp. 1249. DOI: [10.3390/s18041249](https://doi.org/10.3390/s18041249)
7. Podstrigaev A.S., Smolyakov A.V. *Trudy MAI*, 2020, no. 114. URL: <https://trudymai.ru/eng/published.php?ID=118984>. DOI: [10.34759/trd-2020-114-11](https://doi.org/10.34759/trd-2020-114-11)
8. Malygin I.V., Bel'kov S.A., Tarasov A.D., Usvyatsov M.R. *Trudy MAI*, 2017, no. 96. URL: <https://trudymai.ru/eng/published.php?ID=85797>

9. Efimov E.N., Shevgunov T.Ya. *Trudy MAI*, 2015, no. 82. URL: <https://trudymai.ru/eng/published.php?ID=58786>
10. Efimov E.N., Shevgunov T.Ya. *Trudy MAI*, 2012, no. 51. URL: <https://trudymai.ru/eng/published.php?ID=29159>
11. Nikolenko S., Kadurin A., Arkhangel'skaya E. *Glubokoe obuchenie* (Deep Learning), Sankt-Petersburg, Piter, Piter, 2018, 480 p.
12. Bai Shaojie, J. Zico Kolter, and Vladlen Koltun. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling, *Computer Science*, 2018. URL: <https://doi.org/10.48550/arXiv.1803.01271>
13. Hochreiter S., Schmidhuber J. Long short-term memory, *Neural computation*, 1997, vol. 9 (8), pp.1735–1780. DOI: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)
14. Cho Kyunghyun, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using RNN encoder-decoder for statistical machine translation, *Computer Science*, 2014. URL: <https://doi.org/10.48550/arXiv.1406.1078>
15. Bishop C.M. *Pattern Recognition and Machine Learning*, Springer, New York, NY, 2006.
16. Kingma Diederik, Jimmy Ba. Adam: A method for stochastic optimization, *Computer Science*, 2014. URL: <https://doi.org/10.48550/arXiv.1412.6980>
17. Murphy K.P. *Machine Learning: A Probabilistic Perspective*. The MIT Press, Cambridge, Massachusetts, 2012.

18. Pascanu R., Mikolov T., Bengio Y. On the difficulty of training recurrent neural networks, *Proceedings of the 30th International Conference on Machine Learning*, 2013, vol. 28 (3), pp. 1310–1318.
19. Bottou Léon, Bousquet Olivier. The Tradeoffs of Large Scale Learning, *Conference: Advances in Neural Information Processing Systems 20, Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems*, Vancouver, British Columbia, Canada, December 3-6, 2007.
20. Bottou Léon. *Online Algorithms and Stochastic Approximations. Online Learning and Neural Networks*, Cambridge University Press, Cambridge, UK, 1998.

Статья поступила в редакцию 29.11.2023

Одобрена после рецензирования 06.12.2023

Принята к публикации 27.02.2024

The article was submitted on 29.11.2023; approved after reviewing on 06.12.2023; accepted for publication on 27.02.2024