

Н. В. ПАНОКИН, И. А. КОСТИН, А. В. АВЕРИН, А. В. КАРЛОВСКИЙ,
Д. И. ОРЁЛКИНА, А. Ю. НАЛИВАЙКО

ПРИМЕНЕНИЕ МЕТОДА РАЗРЕЖЕННОГО ПРЕДСТАВЛЕНИЯ КОМПЛЕКСНЫХ ДАННЫХ ДЛЯ СИСТЕМ ПОЗИЦИОНИРОВАНИЯ И ПРЕДУПРЕЖДЕНИЯ О СТОЛКНОВЕНИИ НА ЖЕЛЕЗНОДОРОЖНЫХ ПУТЯХ С ИСПОЛЬЗОВАНИЕМ РАДАРА МИЛЛИМЕТРОВОГО ДИАПАЗОНА

В статье представлены результаты экспериментального исследования применения модифицированной искусственной нейронной сети MFNN (Minimum Fuel Neural Network). При этом действует метод разреженного представления комплексных данных с использованием избыточного базиса с оптимизацией за счет норм L_0/L_1 вместо классического алгоритма на основе быстрого преобразования Фурье (БПФ). Продемонстрировано существенное улучшение способности систем распознавания препятствий и автономного управления железнодорожным транспортом различать близкорасположенные друг к другу объекты, такие как составы на соседних путях сортировочных станций.

Ключевые слова: железнодорожный транспорт, распознавание препятствий, радар, угловое разрешение, искусственная нейронная сеть, MFNN, избыточный базис, норма L_0 , норма L_1 .

Введение

В связи с постоянным развитием технологий чувствительных элементов, нейронных сетей и распознавания образов оказывается востребованным автономное управление транспортом. Железнодорожный транспорт не является исключением, и решения, позволяющие повысить безопасность движения, становятся все более актуальными.

Успешное применение методов радиолокации для обеспечения функционирования систем контроля и управления в разных отраслях народного хозяйства обусловлено преимуществами радаров, такими как всепогодность, способность функционировать при полном отсутствии освещения, сравнительно невысокая стоимость, возможность автоматизации и автономность.

Панокин Николай Викторович. Кандидат технических наук, начальник центра перспективных разработок автономных систем, Московский политехнический университет. ORCID 0000-0001-8680-9510.

Костин Иван Александрович. Инженер-исследователь центра перспективных разработок автономных систем, Московский политехнический университет. ORCID 0000-0002-9069-9198.

Аверин Артем Владимирович. Инженер 1 категории центра перспективных разработок автономных систем, Московский политехнический университет.

Карловский Александр Васильевич. Научный сотрудник центра перспективных разработок автономных систем, Московский политехнический университет. ORCID 0000-0001-7660-3375.

Орёлкина Дарья Ивановна. Кандидат технических наук, научный сотрудник центра перспективных разработок автономных систем, Московский политехнический университет.

Наливайко Антон Юрьевич. Кандидат технических наук, проректор по научной работе, Московский политехнический университет. ORCID 0000-0003-2475-4811.

Использование радиолокации и современных методов обработки радиолокационных сигналов открывает ряд перспектив для обеспечения безопасности и автоматизации процессов в сфере железнодорожного транспорта. К возможным сферам применения можно отнести задачи обнаружения технологических препятствий нормальному функционированию снегоочистительной техники, а также выявления транспортных средств в зоне переезда для управления выездными шлагбаумами.

Одним из вариантов решения таких задач является применение радаров миллиметрового диапазона, определяющих направление прихода (Direction of Arrival – DOA) отраженных от препятствий сигналов. Однако при всех своих преимуществах радары обладают низкой угловой разрешающей способностью, что не позволяет гарантированно отличить близкорасположенные составы, находящиеся на соседнем и своем пути. Ситуация дополнительно усложняется на сортировочных станциях с большим количеством составов на путях. Повышение углового разрешения радаров позволило бы использовать их и для позиционирования на путях, поскольку к радиолокационному изображению высокого разрешения применима технология SLAM.

При обработке отраженных сигналов задействуются классические методы – преобразование Фурье, косинусное преобразование и вейвлет-преобразование – с различными базисами для представления данных с помощью разложения на ортогональные функции. Основным недостатком этих методов является низкое угловое разрешение. Улучшить разрешающую способность по углу можно с помощью таких алгоритмов, как MUSIC (Multiple Signal Classification – классификация множественных сигналов) и ESPRIT (Estimation of Signal Parameters via Rotational Invariant Techniques – оценка параметров сигнала посредством преобразований, инвариантных относительно оператора поворота) или MVDR (Minimum Variance Distortion Less Response – минимум дисперсии шума) [1–3]. Вместе с тем для отраженных сигналов, которые обычно сильно коррелированы, лучше всего подходят методы избыточного базиса на основе разреженного представления. Эти методы предполагают использование базиса с большим числом компонент, которые в общем случае не являются ортогональными и позволяют точнее определить направление прихода сигналов [4–7]. В этом случае данные представляются в виде комбинации небольшого числа базисных функций так называемого разреженного представления SR (Sparse Representation). Методы оптимизации, такие как МР (Matching Pursuit – метод согласованного преследования), МОР (Method of Frame – метод фреймовой оптимизации) и ВР (Basis Pursuit – метод поиска базиса) CV-SBM (Complex-Valued Split Bregman Method – оптимизация на основе комплекснозначного расщепления Брегмана) и ряд других [8–16], применяются, чтобы найти оптимальные базисные компоненты разреженного представления из избыточного базисного словаря:

$$\{ \max_{y \in \Omega} y^T x \} \rightarrow \min, \text{ при условии } Ax = b, \quad (1)$$

где $\Omega = \{ \omega \in \mathbb{C}^N \mid |\omega_i| \leq 1, i = 1, 2, \dots, N \} \subset \mathbb{C}^N, b \in \mathbb{C}^M$ – входные данные,

$x = [\alpha_{\gamma_1}, \alpha_{\gamma_2}, \dots, \alpha_{\gamma_N}]^T \in \mathbb{C}^N$ – коэффициенты базиса,

$A = [\phi_{\gamma_1}, \phi_{\gamma_2}, \dots, \phi_{\gamma_N}] \in \mathbb{C}^{M \times N}$ – матрица избыточного базисного словаря,

$D = (\phi_{\gamma})$ – базисный словарь, где $\phi_{\gamma} \in \mathbb{C}^M$ – компоненты базиса с индексом $\gamma \in \Gamma$ и $\Gamma \subset L^2(\mathbb{R})$.

Для определения оптимальности такого представления используются нормы L_0 :

$$L_0 = \left(\sum_{i=1}^I |x_i|^0 \right), \quad |x_i|^0 = \begin{cases} 0, & \text{если } x_i = 0 \\ 1, & \text{иначе} \end{cases}, \quad (2)$$

таким образом, L_0 – количество ненулевых элементов в x , или L_1 :

$$L_1 = \left(\sum_{i=1}^I |x_i|^1 \right). \quad (3)$$

В [15] было показано, что в данном случае нормы L_0 и L_1 эквивалентны.

Результаты теоретических исследований методов DOA изложены во многих работах, включая упомянутые выше.

В настоящей статье представлены результаты эксперимента, в ходе которого оценивались применимость метода DOA и его эффективность для определения наличия объектов (вагоны, локомотивы) на соседних железнодорожных путях с использованием радара миллиметрового диапазона.

Исследуемый метод основан на использовании нейронной сети MFNN [15], модифицированный вариант которой [16] дает возможность работать с комплексными значениями и представляет комплексные сигналы в виде коэффициентов избыточного базиса с минимальной нормой L1.

Методы технического зрения, в том числе с привлечением радаров, востребованы на железнодорожном транспорте (см. [17–19]), однако основным препятствием для широкого применения радаров является, как уже отмечалось, их недостаточная угловая разрешающая способность. В ходе эксперимента проверялось, возможно ли достичь высокой разрешающей способности экспериментального радара при обработке принимаемых сигналов с использованием метода MFNN.

В работе рассмотрены варианты реализации нейронной сети MFNN, описывается ее модификация, приведены условия и результаты экспериментов, сделаны выводы относительно применимости предложенного метода, а также обозначены перспективы его использования для развития систем автономного управления транспортом. Результаты испытаний могут применяться в областях, где требуется высокая разрешающая способность и точность в обработке радарных сигналов.

Модифицированная нейронная сеть

Модифицированный вариант нейронной сети MFNN представлен на рис. 1. Он описывается системой дифференциальных уравнений с комплексными переменными:

$$\begin{cases} \frac{dx}{dt} = -A^T [Ax - y - b] - P_\Omega(x + A^T y), \\ \frac{dy}{dt} = -A[x + A^T y - P_\Omega(x + A^T y)] + b, \\ x \in C^N, y \in C^M, z = x + A^T y, z \in C^N, \end{cases} \quad (4)$$

где $P_\Omega(z) = [P_\Omega(z_1), P_\Omega(z_2), \dots, P_\Omega(z_n)]^T$ – измененная функция активации

$$P_\Omega(z_i) = \begin{cases} \frac{z_i}{|z_i|}, & \text{if } |z_i| > 1, \\ z_i, & \text{if } |z_i| \leq 1, \end{cases} \quad (2)$$

в которой $|z_i| = \sqrt{\text{Re}(z_i)^2 + \text{Im}(z_i)^2}$, $i = 1, 2, \dots, N$, $x = [\alpha_{\gamma_1}, \alpha_{\gamma_2}, \dots, \alpha_{\gamma_N}]^T \in C^N$ – базисные компоненты, $A = [\phi_{\gamma_1}, \phi_{\gamma_2}, \dots, \phi_{\gamma_N}] \in C^{M \times N}$ – матрица словаря избыточного базиса.




Рис. 1. Нейронная сеть MFNN

Нейронная сеть вырабатывает вектор значений комплексных коэффициентов x базисных компонентов. Модули этих коэффициентов являются оценкой уровней отраженных сигналов, приходящих по направлениям, которые соответствуют использованным при формировании словаря избыточного базиса:

$$A_{m,i} = b_k e^{j2\pi d(m-1)\sin(\theta_i)}, \quad (5)$$

где $\theta_i = \frac{180^\circ \cdot i}{N} - 90^\circ$, $i = 1, 2, \dots, N$ – размерность сетки угловых направлений словаря избыточного базиса, $m = 1, 2, \dots, M$ (M – количество антенн приемной эквидистантной решетки радара).

Экспериментальные результаты

Были проведены эксперименты для сцены, в которой присутствуют от одного до трех тестовых отражателей $0,6 \times 0,3$ м с шагом 0,6 м на дальностях 10 и 5 м, имитирующих по угловым размерам вагоны на соседних путях, расположенные на расстояниях 110 и 55 м. Плоские отражатели были покрыты фольгой, воспроизводящей случайное рассеивание на элементах конструкции вагонов (рис. 2, 4, 6). Данные вырабатывал ЛЧМ-радар с рабочей частотой 24 ГГц с 16-канальной антенной решеткой. Результаты приведены на рис. 3, 5, 7, где сверху черными отрезками линий обозначены положение и горизонтальные размеры отражателей, слева представлены результаты работы алгоритма на базе 64-точечного БПФ (рис. 3, 5, 7, а), справа – при использовании избыточного базиса размером 512×16 (рис. 3, 5, 7, б). По оси X для удобства сравнения с результатами, полученными на железнодорожной станции, отложено горизонтальное смещение в метрах, пересчитанное к дистанции 100 м, а по оси Y – относительная величина отклика после БПФ, или значения модулей весовых коэффициентов для рассматриваемого метода на дальности размещения отражателей. Увеличение размерности БПФ свыше 16 для 16-канальной линейной антенной решетки не улучшает угловое разрешение. 64-точечное БПФ выбрано с целью более наглядного отображения формы отклика на отраженные сигналы за счет меньшего

шага по углу в азимутальной плоскости. Вывод о наличии или отсутствии объекта делался по результатам пороговой обработки с помощью алгоритма FAOSOSD (Forward Automatic Order Selection Ordered Statistics Detector – детектор упорядоченной статистики прямого автоматического выбора порядка) [20]. Пороговый уровень на рис. 3, 5, 7 и 9–11 отмечен красным цветом.



Рис. 2. Два тестовых отражателя на дистанции 10 м





Рис. 3. Два тестовых отражателя на дистанции 10 м. Результаты обработки отраженных сигналов: а) на базе 64-точечного БПФ; б) при использовании избыточного базиса



Рис. 4. Три тестовых отражателя на дистанции 10 м





Рис. 5. Три тестовых отражателя на дистанции 10 м. Результаты обработки отраженных сигналов: а) на базе 64-точечного БПФ; б) при использовании избыточного базиса

Можно заключить, что там, где обычная обработка на базе БПФ дает одну отметку от трех близкорасположенных объектов (рис. 5, а), предложенный метод позволяет существенно повысить разрешение и четко выделить каждый объект (рис. 5, б).



Рис. 6. Три тестовых отражателя на дистанции 5 м

Корреляция отраженных сигналов сильно влияет на результат, полученный при использовании БПФ. На рис. 7, а для трех отражателей на дистанции 5 м видны только два пика, поэтому легко сделать ложный вывод об отсутствии центрального отражателя. В то же время благодаря предложенному методу выделяются весовые коэффициенты с уровнем выше порогового в областях всех трех отражателей, что хорошо видно на рис. 7, б.

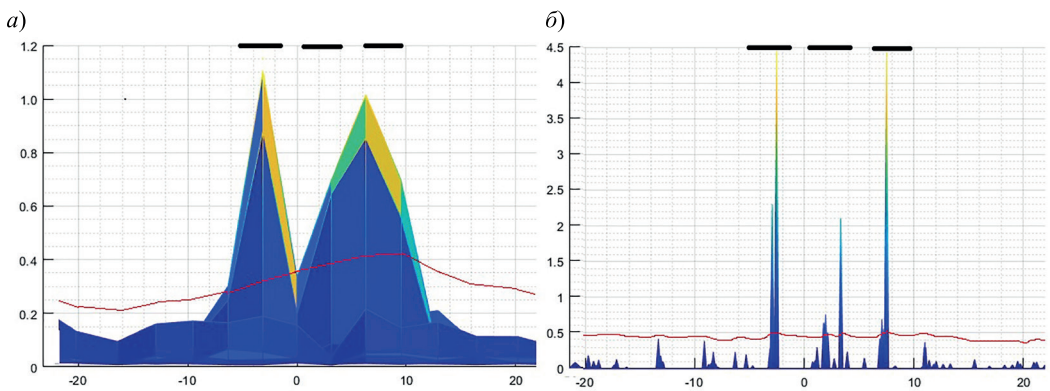


Рис. 7. Три тестовых отражателя на дистанции 5 м. Результаты обработки отраженных сигналов: а) на базе 64-точечного БПФ; б) при использовании избыточного базиса

Результаты, приведенные на рис. 9–11, были получены с помощью радара, установленного на одном из путей (основном) на сортировочной станции. Измерения проводились при наличии от одного до трех составов на основном и на соседних путях. Дистанция до ближайшего вагона составов была одинаковой и составляла 100 м. Пример расположения железнодорожных составов на сортировочной станции приведен на рис. 8.



Рис. 8. Железнодорожные составы на сортировочной станции

На рисунках снизу черными прямоугольниками обозначены положение и горизонтальные размеры вагонов, слева показаны результаты работы алгоритма на базе 64-точечного БПФ (рис. 9–11, *а*), справа – рассматриваемого метода при использовании избыточного базиса (рис. 9–11, *б*). По оси *X* отложено горизонтальное смещение в метрах, а по оси *Y* относительная величина отклика после БПФ или значения модулей весовых коэффициентов для рассматриваемого метода на дальности 100 м.




Рис. 9. Один вагон на основном пути на дистанции 100 м.
Результаты обработки отраженных сигналов: *а*) на базе 64-точечного БПФ;
б) при использовании избыточного базиса

Из рис. 9 видно, что для рассматриваемого метода найденные весовые коэффициенты позволяют четко определить положение вагона, включая его границы. В то же время на уровне -3 дБ БПФ показывает область возможного положения вагона размером более 10 м.




Рис. 10. Два вагона на соседних путях на дистанции 100 м.
Результаты обработки отраженных сигналов

При наличии вагонов на смежных путях и отсутствии на основном с помощью БПФ нельзя точно узнать, что основной путь свободен – по отклику можно сделать ошибочный вывод, что занят только правый путь (рис. 10). В то же время рассматриваемый метод позволяет определить направления на оба вагона на соседних путях и сделать вывод о том, что основной путь свободен.

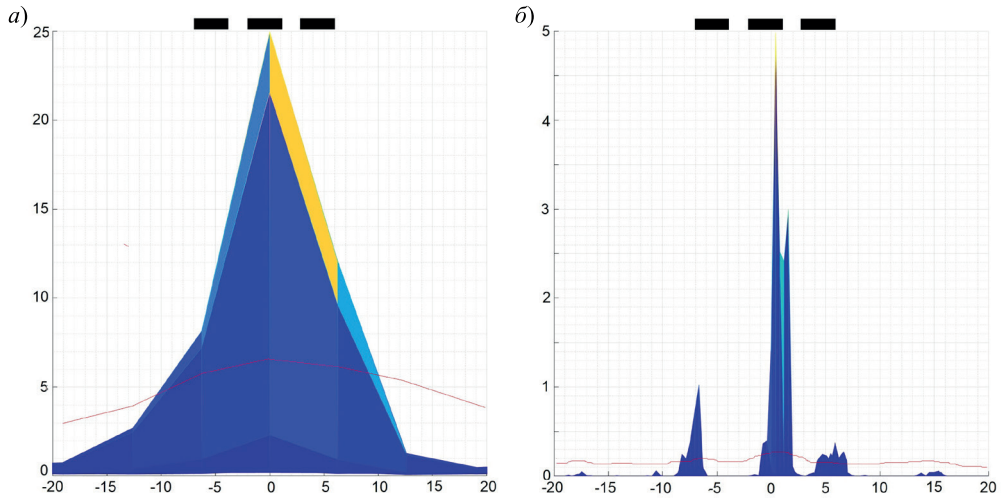


Рис. 11. Три вагона на соседних путях на дистанции 100 м.
Результаты обработки отраженных сигналов

Случай, когда на всех трех смежных путях стоят вагоны, показан на рис. 11. Видно, что БПФ не дает возможности определить число занятых путей в отличие от модифицированной нейронной сети, которая дала значимый отклик по всем трем направлениям, что на дистанции эквивалентно угловому разрешению лучше $0,8^\circ$.

Использование нейронных сетей вместо классических алгоритмов быстрого преобразования Фурье также приводит к положительным результатам. Это делает нейронные сети перспективным направлением для развития систем распознавания препятствий и автономного управления транспортом.

Заключение

Эксперименты продемонстрировали, что метод разреженного представления данных на модифицированной нейронной сети, избыточного базиса и нормы L_0 (в [11] было показано, что в данном случае нормы L_0 и L_1 эквивалентны) позволяет улучшить способность системы на базе радара миллиметрового диапазона различать близкорасположенные объекты. Это делает нейронные сети перспективным направлением для развития систем как распознавания препятствий, так и реализующих SLAM-позиционирование по опорным точкам радиолокационного изображения. Применение нейронных сетей, современных чувствительных элементов и технологий распознавания образов позволяет разрабатывать инновационные решения для управления железнодорожными системами и дальнейшего развития систем автономного управления транспортом.

Исследование выполнено при поддержке министерства науки и высшего образования Российской Федерации, грант FZRR-2023-0008.

ЛИТЕРАТУРА

1. Cheng, P., Wang, X., Zhao, J., and Cheng, J., A Fast and Accurate Compressed Sensing Reconstruction Algorithm for ISAR Imaging, *IEEE Access*, 2019, vol. 7, pp. 157019–157026, doi: 10.1109/ACCESS.2019.2949756.
2. Roy, R., Kailath, T., ESPRIT-estimation of signal parameters via rotational invariance techniques, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Jul 1989, vol. 37, no. 7, pp. 984–995, doi: 10.1109/29.32276.
3. Souden, M., Benesty, J., Affes, S., On optimal frequency domain multichannel linear filtering for noise reduction, *IEEE Transactions on Audio, Speech, and Language Processing*, 2010, vol. 18, no. 2, pp. 260–276, doi: 10.1109/TASL.2009.2025790.
4. Cichocki, A., Unbehauen, R., Neural networks for solving systems of linear equations – Part II: Minimax and least absolute value problems, *IEEE Trans. Circuits Syst.*, Sept. 1992, vol. 39, pp. 619–633, doi:10.1109/82.193316.
5. **Neural Networks for Optimization and Signal Processing**, Stuttgart, Germany: Teubner-Wiley, 1993.
6. Xiong, K., Zhao, G., Shi, G., Wang, Y., A Convex Optimization Algorithm for Compressed Sensing in a Complex Domain: The Complex-Valued Split Bregman Method, *Sensors (Basel)*, 2019, Oct. 18;19(20):4540, doi: 10.3390/s19204540. PMID: 31635423; PMCID: PMC6832202.
7. Stanković, L., Sejdić, E., Stanković, S. et al., A Tutorial on Sparse Signal Reconstruction and Its Applications in Signal Processing, *Circuits Syst Signal Process*, 2019, vol. 38, pp. 1206–1263, doi: 10.1007/s00034-018.9-0909-2.
8. Changhao Yi, Cunlu Zhou, Jun Takahashi, Quantum Phase Estimation by Compressed Sensing, <https://doi.org/10.48550/arXiv.2306.07008>.
9. Bandler, J.W., Kellerman, W., Madsen, K., A non-linear L1 optimization algorithm for design, modeling, and diagnosis of networks, *IEEE Trans. Circuits Syst.*, Feb. 1987, vol. 34, pp. 174–18.91, doi: 10.1109/TCS.1987.1086100.
10. Zhang, Y., Xiao, S., Huang, D., Sun, D., Liu, L., Cui, H., L0-norm penalised shrinkage linear and widely linear LMS algorithms for sparse system identification, *IET Signal Process*, 2017, vol. 11, pp. 86–94, doi: 10.1049/iet-spr.2015.0218.
11. Ishii, Y., Koide, S., Hayakawa, K., L0-norm Constrained Autoencoders for Unsupervised Outlier Detection, *Lauw, H., Wong, RW., Ntoulas, A., Lim, EP., Ng, SK., Pan, S. (eds) Advances in Knowledge Discovery and Data Mining. PAKDD 2020. Lecture Notes in Computer Science*, vol. 12085, Springer, Cham., doi: 10.1007/978-3-030-47436-2_51.
12. Rajko, R., Studies on the adaptability of different Borgen norms applied in selfmodeling curve resolution (SMCR) method, *Journal of Chemometrics*, 2009, vol. 23(6), pp. 265–274, doi: 10.1002/cem.1221.
13. Jahan, K., Niemeijer, J., Kornfeld, N., Roth, M., Deep Neural Networks for Railway Switch Detection and Classification Using Onboard Camera, *IEEE Symposium Series on Computational Intelligence*, October 2021, doi:10.1109/SSCI150451.2021.9659983.
14. Malioutov, D.M., Cetin, M., Willsky, A.S., Optimal sparse representations in general overcomplete bases, *Proceedings of the 2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, Montreal, QC, Canada, 2004, pp. ii-793, doi: 10.1109/ICASSP.2004.1326377.
15. Wang, Z.S., Cheung, J.Y., Xia, Y.S., Chen, J.D.Z., Minimum fuel neural networks and their applications to overcomplete signal representations, *IEEE Transactions on Circuits and Systems I Fundamental Theory and Applications*, 2000, vol. 47(8), pp. 1146–1159, doi: 10.1109/81.873870.
16. Panokin, N.V., Averin, A.V., Kostin, I.A., Karlovskiy, A.V., Orelkina, D.I., and Nalivaiko, A.Yu., 2024. Method for Sparse Representation of Complex Data Based on Overcomplete Basis, l1 Norm, and Neural MFNN-like Network Applied Sciences 14, no. 5: 1959. <https://doi.org/10.3390/app14051959>.
17. Охотников А.Л. Алгоритм выбора оборудования для систем технического зрения на железнодорожном транспорте // Наука и технологии железных дорог. 2021. Т. 5, № 1 (17). С. 65–74. EDN: TWRACV.
18. Хатламаджиян А.Е., Орлов В.В., Николаев И.С. Повышение безопасности движения поездов с помощью бортовой системы технического зрения // Эксплуатационная надежность локомотивного парка и повышение эффективности тяги поездов: материалы VII Всероссийской научно-технической конференции с международным участием. Омск: ОмГУПС, 2022. С. 328–334. EDN: JTLVDQ.
19. Машенко П.Е., Шутилов К.В. Анализ сенсоров систем технического зрения для нужд промышленного железнодорожного транспорта // Вестник Института проблем естественных монополий: Техника железных дорог. 2021. № 1 (53). С. 40–45. EDN: FEUABX.

20. Magaz, B., Belouchrani, A., Hamadouche, M., Automatic Threshold Selection in Os-Cfar Radar Detection Using Information Theoretic Criteria, *Progress In Electromagnetics Research B*, 2011, 30, 157–175, doi:10.2528/PIERB10122502.
-

Panokin, N.V., Kostin, I.A., Averin, A.V., Karlovskiy, A.V., Orelkina, D.I., and Nalivaiko, A.Yu. (Moscow Polytechnic University, Moscow, Russia)

Application of Sparse Representation of Complex Data in Railway Positioning and Collision Alert Systems Using Millimeter Wave Radar, *Giroskopiya i Navigatsiya*, 2024, vol. 32, no. 1 (124), pp. 84–93.

Abstract. The article presents the results from the experimental study of a modified artificial neural network MFNN (minimum fuel neural network). Sparse representation of complex data with overcomplete basis and L_0/L_1 norm optimization is used instead of the classical fast Fourier transform (FFT) algorithm. The results showed a significant enhancement in the abilities of obstacle recognition and autonomous railway control systems to distinguish between close objects, such as trains on adjacent tracks of marshalling yards.

Key words: railway transport, obstacle recognition, radar, angular resolution, artificial neural network, MFNN, overcomplete basis, L_0 norm, L_1 norm.

Материал поступил 15.01.2024