

<https://doi.org/10.17073/2072-1633-2025-2-1420>

Разработка стратегии инновационного развития промышленности в регионах России с применением машинного обучения

С.Н. Яшин, Е.В. Кошелев ✉, А.А. Иванов

Нижегородский государственный университет им. Н.И. Лобачевского,
603022, Нижний Новгород, просп. Гагарина, д. 23, Российская Федерация
✉ ekoshelev@yandex.ru

Аннотация. Технологии машинного обучения являются достаточно мощным инструментом анализа больших данных, поэтому могут быть применены в российских регионах для разработки стратегии инновационного развития промышленности. Для сравнения результатов качества прогнозирования и выбора наиболее оптимального метода на примере радиоэлектронной промышленности (РЭП) применен способ «машинного обучения k -ближайших соседей», нейронные сети «многослойный перцептрон» и адаптивная нейро-нечеткая система вывода, включающая в себя алгоритм роя частиц, а также многомерные адаптивные регрессионные сплайны. В качестве целевых функций рассмотрены: 1) объем инновационных товаров; 2) разработанные передовые производственные технологии; 3) сальдированный финансовый результат (информатизация и связь). Представленная модель прошла обучение на основе выборки пакета девяти входных и трех целевых показателей в период с 2010 по 2022 г. для 83 регионов России. Для последующей верификации обученной модели оставлен 2023 г. выборки. Наиболее качественный прогноз был получен с помощью алгоритма машинного обучения k -ближайших соседей. При проведении оценки было установлено, что перспективы инновационного развития в отрасли имеют те регионы, у которых значения прогнозных целевых функций попадают в плановые сегменты в 2023 г. Оценка проводилась лишь в тех регионах, для которых прогноз считался наиболее качественным, т.е. средняя абсолютная процентная ошибка $< 0,5$, это – Краснодарский и Пермский край, Нижегородская, Свердловская, Челябинская и Новосибирская области. При выполнении подобного анализа для алгоритмов многомерных адаптивных регрессионных сплайнов (для цели 3), роя частиц (для цели 2), многослойных перцептронов (для цели 1), было установлено, что претендующими на лидерство в отрасли РЭП имеют Нижегородская и Свердловская области, что частично подтверждает выводы, полученные с помощью способа машинного обучения.

Ключевые слова: радиоэлектронная промышленность, инновационное развитие, машинное обучение, k -ближайших соседей, многослойный перцептрон, адаптивная нейро-нечеткая система вывода, алгоритм роя частиц, многомерные адаптивные регрессионные сплайны

Благодарности: Исследование выполнено при финансовой поддержке гранта Российского научного фонда (проект № 24-28-00464).

Для цитирования: Яшин С.Н., Кошелев Е.В., Иванов А.А. Разработка стратегии инновационного развития промышленности в регионах страны с применением машинного обучения. *Экономика промышленности*. 2025;18(2):241–253. <https://doi.org/10.17073/2072-1633-2025-2-1420>

Creation of a strategy for the innovative development of industry in the regions of Russia using machine learning

S.N. Yashin, E.V. Koshelev✉, A.A. Ivanov

National Research Lobachevsky State University of Nizhny Novgorod,
23 Gagarina Ave., Nizhni Novgorod 603950, Russian Federation

✉ ekoshelev@yandex.ru

Abstract. Machine learning technology is a powerful tool for analyzing big data, and thus they can be applied to create a strategy for innovative development of industry in the regions of Russia. To compare the results of the quality of forecasting and to choose the most optimal method on the example of radio-electronic industry (REI), the authors applied the method of “k-nearest neighbor machine learning”, neural networks “multilayer perceptron” and adaptive neuro-fuzzy inference system which includes a particle swarm algorithm as well as multidimensional adaptive regression splines. The following functions were studied as the target ones: 1) the volume of innovative goods; 2) developed advanced production technologies; 3) net financial result (informatization and communication). The suggested model was trained on the basis of a sample package of nine inputs and three targets in 2010–2022 in 83 regions of Russia. For further verification of the trained model the year of 2023 was chosen as a sample package. It was stated that the highest quality forecast was made with the k-nearest neighbors machine learning algorithm. During the assessment, it was established that the prospects for innovative development in the industry can be found in the regions where the values of the predicted target functions fall into the planned segments in 2023. The assessment was conducted only in those regions whose forecast was regarded as the highest quality (with the average absolute percentage error < 0,5). These regions include the Krasnodar and the Perm territories, and Nizhny Novgorod, Sverdlovsk, Chelyabinsk and Novosibirsk regions. When performing similar analysis for algorithms of multidimensional adaptive regression splines (for target 3), particle swarm (for target 2), multilayer perceptrons (for target 1), the authors established that Nizhny Novgorod and Sverdlovsk region can be regarded as leaders in the REI industry, and this partially confirms the conclusions obtained by the machine learning method.

Keywords: radio electronic industry, innovative development, machine learning, k-nearest neighbors, multilayer perceptron, adaptive neuro-fuzzy inference system, particle swarm algorithm, multidimensional adaptive regression splines

Acknowledgements: The research was carried out with the financial support of a grant from the Russian Science Foundation (project № 24-28-00464).

For citation: Yashin S.N., Koshelev Y.V., Ivanov A.A. Creation of a strategy for the innovative development of industry in the regions of Russia using machine learning. *Russian Journal of Industrial Economics*. 2025;18(2):241–253. <https://doi.org/10.17073/2072-1633-2025-2-1420>

利用机器学习制定俄罗斯地区创新型工业发展战略

S.N. 亚辛、E.V. 科舍列夫✉、A.A. 伊万诺夫

下诺夫哥罗德罗巴切夫斯基国立大学、603022, 俄罗斯联邦下诺夫哥罗德市加加林大街23号

✉ ekoshelev@yandex.ru

摘要: 机器学习技术是分析大数据的有力工具, 因此可以应用于俄罗斯各地区制定创新型工业发展战略。为了比较预测质量的结果并选择最优方法, 以无线电电子工业为例, 我们应用了k-近邻算法、“多层感知器”神经网络和自适应神经模糊推理系统(包括粒子群算法和多元自适应回归样条法)。目标函数如下: 1) 创新产品的数量; 2) 先进生产技术的发展; 3) 平衡的财务结果(信息化和通信)。该模型是在2010年至2022年期间俄罗斯83个地区的九项输入指标和三项目标指标样本包的基础上进行训练的。为进一步验证训练后的模型, 保留了2023年的样本。结果发现, 使用k-近邻算法获得了最高质量的预测。在评估过程中发现, 2023年预测目标函数值在计划范围内的地区具有工业创新发展前景。评估仅在预测被认为质量最高的地区进行, 即平均绝对百分比误差小于0.5的地区, 这些地区是克拉斯诺达尔边疆区和彼尔姆边疆区、下诺夫哥罗德州、斯维尔德洛夫斯克州、车里雅宾斯克州和新西伯利亚州。在对多元自适

应回归样条法 (目标 3)、粒子群算法 (目标 2)、多层感知器算法 (目标 1) 进行类似分析后发现下诺夫哥罗德州和斯维尔德洛夫斯克州在无线电电子工业领域处于领先地位, 这在一定程度上证实了使用机器学习方法得出的结论。

关键词: 无线电电子工业、创新发展、机器学习、k-近邻算法、多层感知器、自适应神经模糊推理系统、粒子群算法、多元自适应回归样条法

致谢: 本研究得到了俄罗斯科学基金会的资助 (项目编号: 24-28-00464)。

Введение

Разработка стратегии инновационного развития промышленности является важным направлением наращивания отечественного технологического лидерства. В ряде научных публикаций на эту тему рассматриваются показатели экспорта и импорта технологий [1; 2]. Однако их недостаточно для оценки разнообразных перспектив стратегического развития промышленности. Необходимы дополнительные целевые показатели, а также более мощные технологии анализа больших данных (Big Data).

Технологии машинного обучения (Machine Learning, ML) для этого являются достаточно мощным инструментом, а поэтому могут быть применены для оценки перспектив инновационного развития отрасли, например, радиоэлектронной промышленности (РЭП) в регионах страны.

Ниже проведен краткий обзор последних достижений в области технологий машинного обучения.

В исследовании М. Йосефзадэ-Наджафабади и др. (M. Yoosefzadeh-Najafabadi et al.) [3] была оценена надежность трех распространенных алгоритмов – ML, многослойного перцептрона (MLP), опорной векторной машины (SVM) и «случайного леса» (RF) для прогнозирования урожайности семян сои (*Glycine max*) с использованием гиперспектрального отражения. Алгоритм RF имел самую высокую производительность со значением точности классификации урожайности (84 %) среди всех отдельно протестированных алгоритмов.

Основная задача машинного обучения заключается в достижении баланса между эффективностью модели и ее предсказуемостью (обобщением) и интерпретируемостью (А. Рамезанпур и др. (Ramezanpour A. et al.)) [4]. В качестве альтернативного подхода можно включить измерение времени в диагностические проблемы, чтобы извлечь выгоду из динамической информации, предоставляемой историей наблюдаемых признаков. В данном случае основной задачей является построение правдоподобных моделей, которые позволяют количественно оценить изменения потенциального риска различных заболеваний со временем. Это достигается за счет

возможности снижения вычислительной сложности диагностических задач за счет использования вычислительной мощности квантовой оптимизации и алгоритмов обучения.

В работе Ж.А. Околи и др. (J.A. Okolie et al.) [5] представлен обзор последних достижений в использовании методов ML для исследования области фармацевтической адсорбции на биоугле.

В статье А. Джайсвала и др. (A. Jaiswal et al.) подробно рассмотрены последние наиболее эффективные методы самоконтроля, которые следуют за контрастным обучением как для задач визуального восприятия, так и для обработки естественного языка. Работы, основанные на контрастном обучении, показали многообещающие результаты для нескольких нисходящих задач, таких как классификация изображений/видео, обнаружение объектов и задачи обработки естественного языка [6].

В работе С. Флира и др. (S. Fleer et al.) [7] недавние достижения в области рекуррентных моделей визуального внимания связаны с предыдущими идеями об организации человеческого тактильного поискового поведения, исследовательских процедур и тактильных взглядов для новой архитектуры, которая изучает генеративную модель тактильного исследования в моделируемой трехмерной среде. Полученный авторами метод был успешно протестирован с четырьмя различными объектами. Он достиг результатов близких к 100 % при выполнении исследования контура объекта, оптимизированного под морфологию его собственного датчика.

Так как в данной статье проводится сравнение результатов ML для оценки перспектив инновационного развития РЭП в регионах страны, используя различные подходы к решению задачи регрессии для квазивременного ряда, проанализируем последние научные достижения в применяемых нами алгоритмах. Это прежде всего алгоритм ML k -ближайших соседей (K -nearest Neighbors, KNN), два алгоритма обучения нейронных сетей: MLP и адаптивная нейро-нечеткая система вывода (Adaptive Neuro-Fuzzy Inference System, ANFIS), дополненная алгоритмом роя частиц (Particle Swarm Optimization, PSO) для глобальной минимизации

ошибки обучения сети, а также, многомерные адаптивные регрессионные сплайны (Multivariate Adaptive Regression Splines, MARS).

Алгоритмы, проанализированные в исследовании С.М. Пирионеси и Т.Е. Ель-Дираби (S.M. Piryonesi, T.E. El-Diraby) [8], включают следующие типы решений: наивный байесовский классификатор, наивный байесовский классификатор в сочетании с ядрами, логистическую регрессию, KNN, RF и «дерева с градиентным усилением». Все они применялись для прогнозирования ухудшения индекса состояния дорожного покрытия (PCI). Точность некоторых моделей в данном прогнозировании через три года превысила 90 %.

В статье С. Уддина и др. (S. Uddin et al.) [9] представлено исследование различных вариантов KNN (классический, адаптивный, локально адаптивный, кластеризация k -средних, нечеткий, взаимный, ансамблевый, Hassanaat и обобщенное среднее расстояние) и сравнение их производительности для прогнозирования заболеваний. Вариант Hassanaat KNN показал самую высокую среднюю точность (83,62 %), за ним следует ансамблевый подход KNN (82,34 %).

Исследование Р.К. Халдера и др. (R.K. Halder et al.) [10] внесло вклад в репертуар алгоритмов ML для классификации больших данных (Big Data), создав сложный, надежный и эффективный инструмент, сочетающий в себе основные преимущества KNN с инновационными усовершенствованиями для удовлетворения потребностей современного ландшафта данных. Это прежде всего улучшение точности классификации: обеспечение того, чтобы усовершенствованная модель KNN классифицировала крупномасштабные данные со значительно низким уровнем ошибок, что является существенным улучшением по сравнению с ее традиционным аналогом в точности и надежности.

В статье Л. Ксионга и Ю. Яо (L. Xiong, Y. Yao) [11] разработана модель теплового комфорта на основе KNN для создания персонализированной среды для адаптации к предпочтениям жильцов. Данная модель может регулировать границу теплового комфорта для одного конкретного человека в соответствии с изменяющимися условиями окружающей среды. Результаты испытаний показали, что процентная точность модели KNN с 1000 наборами обучающих данных может достигать 88,31 % и удовлетворить практический спрос.

В работе С. Патчанока и С. Корна (S. Patchanok, S. Korn) [12] представлена регрессия случайного ядра KNN (Random Kernel KNN, RK-KNN). Такая процедура хорошо подходит для приложений Big Data. По сравнению со стандартными моде-

лями KNN и случайными моделями KNN (R-KNN) она значительно снижает среднеквадратичную ошибку (Root Mean Square Error, RMSE) и среднюю абсолютную ошибку (Mean Absolute Percentage Error, MAPE), а также улучшает значения коэффициента детерминации (R^2).

В статье Е. Зардини, Е. Бланзиери и Д. Пасторелло (E. Zardini, E. Blanzieri, D. Pastorello) [13] представлен новый квантовый алгоритм KNN, основанный на евклидовом расстоянии. В частности, алгоритм характеризуется квантовым кодированием, требующим небольшого количества кубитов, и простой квантовой схемой, не включающей оракулы – аспекты, которые благоприятствуют его реализации. Результаты показали правильность формулировки, падение производительности алгоритма при ограниченном количестве измерений, конкурентоспособность по отношению к некоторым классическим базовым методам в идеальном случае и возможность улучшения производительности за счет увеличения количества измерений.

Алгоритм KNN прост в реализации и понимании, но имеет существенный недостаток: он становится значительно медленнее по мере роста размера используемых данных, в то время как идеальное значение k для классификатора KNN трудно установить [14].

Рассмотрим практические преимущества MLP.

В работе Ж. Исабона и др. (J. Isabona et al.) [15] представлена разработанная отличительная модель потери пути на основе MLP нейронной сети с хорошо структурированной архитектурой сети реализации, усиленная методом настройки гиперпараметров на основе поиска сетки. Предлагаемая модель разработана для оптимальной аппроксимации потери пути между мобильной и базовой станциями. Результаты апробации данной модели показали, что ошибки прогнозирования предлагаемой модели MLP выгодно отличаются от измеренных данных и были лучше, чем ошибки, полученные с использованием обычных моделей потери пути на основе логарифмического расстояния.

Цель исследования К.А. Рашеди и др. (K.A. Rashedi et al.) [16] заключалась в том, чтобы обнаружить выбросы в ежедневных индексах цен акций на фондовой бирже Саудовской Аравии (Tadawul) наблюдениями с октября 2011 г. по декабрь 2019 г. Авторы применили алгоритм MLP для обнаружения выбросов в доходности акций. Результаты демонстрируют эффективность и хорошую производительность алгоритма MLP на основе различных критериальных тестов.

Адаптивная система ANFIS имеет свои практические преимущества. Так, в исследовании В.Д. Сагиаса и др. (V.D. Sagias et al.) [17] пред-

ставлено новое применение ANFIS для прогнозирования механических свойств образцов полимолочной кислоты (PLA), полученных с использованием метода послойного наплавления нитей (FFF). Модель ANFIS объединяет сильные стороны нейронных сетей и нечеткой логики для установления соответствия между входными и выходными механическими свойствами, в частности, максимальным напряжением, деформацией и модулем Юнга.

Исследование В.Г.В. Путры и Ж.Н. Мохамеда (V.G.V.Putra, J.N. Mohamad) [18] было направлено на изучение влияния параметров электроспиннинговой обработки на диаметры нановолокон с использованием искусственных нейронных сетей (ANN) и ANFIS и оценку способности этих методов прогнозировать диаметры нановолокон. Результаты показали, что разработанные ANN и ANFIS могут точно предсказать экспериментальные данные в деталях.

Однако алгоритм ANFIS можно усилить, если добавить к нему глобальную оптимизацию ошибки обучения сети, что позволяет сделать алгоритм роя частиц (Particle Swarm Optimization, PSO). Так, чтобы преодолеть недостатки преждевременной сходимости и легкого попадания в локальные оптимальные решения, в статье Ж. Кьяо и др. (J. Qiao et al.) [19] предлагается улучшенный алгоритм оптимизации роя частиц (PSO), основанный на нескольких гибридных стратегиях. Результаты моделирования доказывают, что данный алгоритм получает лучшие результаты для всех наборов данных, чем другие варианты PSO.

Используя характеристики поиска остановки скорости и механизм замены терминала, проблема преждевременной сходимости, присущая стандартным алгоритмам PSO, смягчается. Алгоритм, представленный К. Тангом и Л. Менгом (Tang K., Meng C.) [20] дополнительно уточняет и контролирует пространство поиска роя частиц с помощью изменяющихся во времени коэффициентов инерции, концепций симметричных кооперативных роев и адаптивных стратегий, уравновешивая глобальный поиск и локальную эксплуатацию PSO. Экспериментальные результаты показывают, что представленный алгоритм демонстрирует значительную конкурентоспособность по сравнению с другими алгоритмами.

Таким образом, в дальнейшем будем использовать алгоритм ANFIS-PSO, т.е. ANFIS, дополненный алгоритмом PSO.

В ряде практических задач эффективным оказывается алгоритм MARS. Он позволяет получить более качественные результаты на плохих, т.е. зашумленных, данных.

В исследовании Р.М. Аднан и др. (R.M. Adnan et al.) [21] точность прогнозирования новых эвристических методов, оптимально обрезанной экстремальной обучающей машины (OP-ELM), машины опорных векторов наименьших квадратов (Least Squares Support Vector Machines, LSSVM), MARS и «дерева» моделей M5 (M5Tree) рассматривается при моделировании ежемесячного стока с использованием осадков и температурных входных данных. Результаты испытаний двух станций показывают, что модели на основе LSSVM и MARS обеспечивают более точные результаты прогнозирования по сравнению с моделями OP-ELM и M5Tree.

Целью исследования А. Хвайди и др. (A. Hwaidi et al.) [22] была разработка модели ML для прогнозирования прочности на сжатие экологически чистого бетона с использованием MARS. Результаты алгоритма прогнозирования MARS сравнивались с результатами алгоритмов регрессии машины SVM и RF с использованием обучающего набора. Показатели производительности показали превосходство модели MARS.

В данном исследовании оценки перспектив инновационного развития РЭП в регионах страны для анализа Big Data будем использовать метод KNN, MLP и ANFIS-PSO, а также алгоритм MARS, чтобы затем сравнить результаты качества прогнозирования разными методами и выбрать оптимальный.

Модель

На **рис. 1** представлены этапы ML оценки перспектив инновационного развития РЭП в регионах России. Опишем их подробнее.

Этап 1 – сбор данных. Проводился с 2010 по 2023 г. по 83 регионам страны. На данном этапе собираются данные о входных переменных (x_i) и значениях целевых функций (y_j), представленных на **рис. 2**. При этом необходимо использовать данные за длительный срок, поэтому берется период времени с 2010 по 2023 г. Все эти данные собираются для 83 регионов России, которые, начиная с 2010 г., существуют.

Этап 2 – корректировка на инфляцию, нормализация и линейаризация данных. Все данные, которые представлены в рублях, должны быть сравнимы между собой. Для этого с сайта Банка России берутся данные годовой инфляции (www.cbr.ru) и умножаются на темпы инфляции с 2010 по 2022 г. Таким образом, получаются данные в ценах последнего 2023 г.

Далее, чтобы в процессе обучения модели веса входных переменных (x_i) не искажались,

необходимо входные переменные привести к одной размерности. В данном случае стандартизация данных не подойдет, поскольку стандартизированные данные не распределены по нормальному закону, что влечет за собой необходимость их линеаризации. Однако в этом случае придется брать натуральный логарифм от некоторых отрицательных значений, что в принципе невозможно. По этой причине при-

меняется не стандартизация, а нормализация данных по формуле

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}},$$

где \tilde{x} – новое значение входной переменной; x – старое значение входной переменной; x_{\min} – ее минимальное значение; x_{\max} – ее максимальное значение.

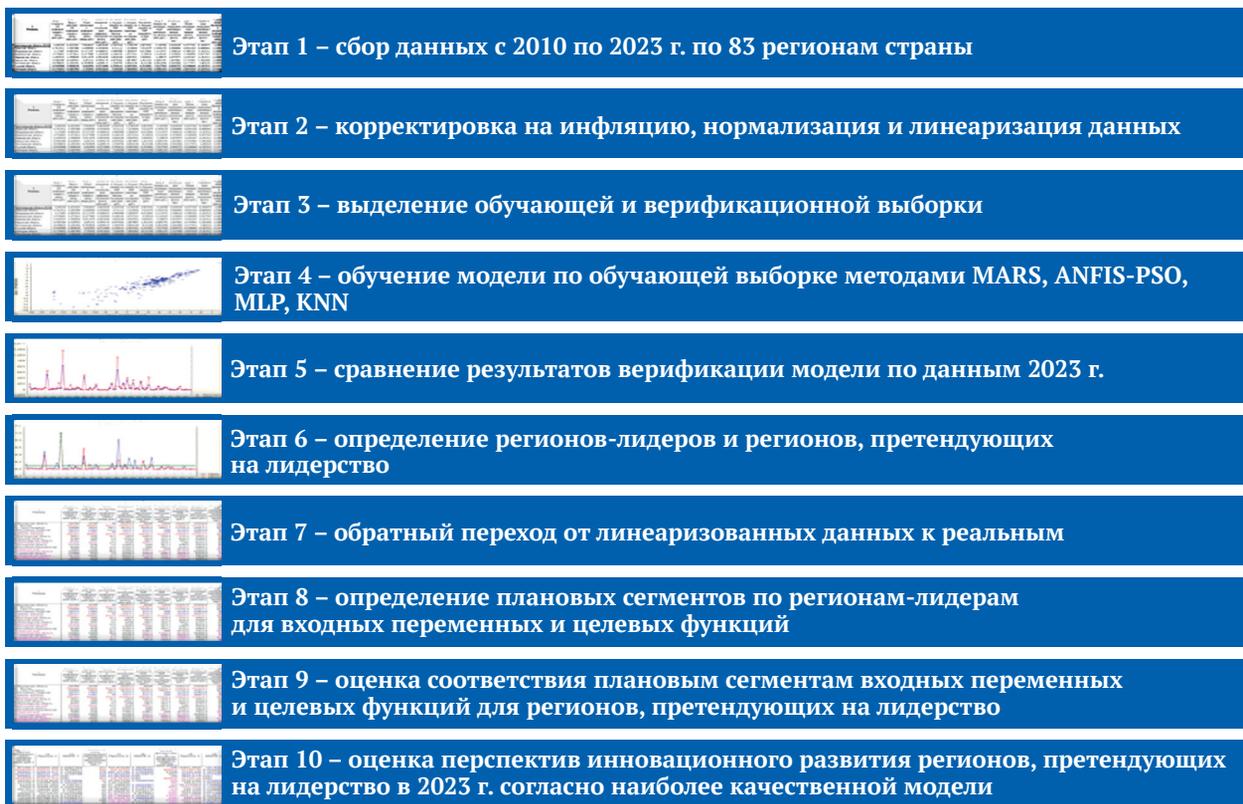


Рис. 1. Этапы машинного обучения оценки перспектив инновационного развития радиоэлектронной промышленности

Fig. 1. Machine learning stages of assessing the prospects for innovative development of the electronic industry

1 Регионы	2 Вход 1 - Стоимость ОФ (информат изация и связь) (млн руб.)	3 Вход 2 - Ввод в действие ОФ (информат изация и связь) (млн руб.)	4 Вход 3 - Оборот организаци и (информат изация и связь) (млрд руб.)	5 Вход 4 - Затраты на внедрение и использов ание цифровых технологий (млн руб.)	6 Вход 5 - Внутренни е текущие затраты на НИР (фундамен тальные исследования) (млн руб.)	7 Вход 6 - Внутренни е текущие затраты на НИР (прикладн ые исследования) (млн руб.)	8 Вход 7 - Внутренни е текущие затраты на НИР (разработк и) (млн руб.)	9 Вход 8 - Затраты на инновацио нную деятельно сть (всего) (млн руб.)	10 Вход 9 - Используй мые передовые производст венные технологии (всего) (ед.)	11 Цель 1 - Объем инновацио нных товаров (всего) (млн руб.)	12 Цель 2 - Разработа нные передовые производст венные технологии (всего) (ед.)	13 Цель 3 - Сальдиров анный финансовы й результат (информат изация и связь) (млн руб.)
1 Белгородская область (2010)	-5,445526	-6,4252591	-7,0934032	-5,8622438	-5,5597234	-5,1781479	-5,8073301	-5,149708	-2,8329228	-4,1077192	-4,1956971	-2,298636
2 Брянская область	-4,7413912	-5,5087888	-5,6389006	-6,4356458	-6,911112	-7,2336656	-7,0222479	-6,3450278	-3,0068844	-4,8581426	-4,8888442	-2,3268512
3 Владимирская область	-5,171483	-4,9835541	-8,3171787	-6,5068352	-3,9445966	-5,3856597	-4,6133842	-5,3115972	-1,9384318	-4,7465325	-13,815511	-2,3240839
4 Воронежская область	-3,9736601	-5,2573812	-6,2277868	-5,2303928	-5,3385193	-3,8737221	-3,558518	-5,1120195	-2,1978059	-3,7499099	-3,4537597	-2,3167778
5 Ивановская область	-5,3459535	-5,5906058	-9,0511478	-6,9053638	-5,6026106	-5,8287631	-7,6565051	-5,348074	-3,6970975	-5,4393167	-13,815511	-2,3268512
6 Калужская область	-4,9385388	-6,0189953	-8,491532	-6,0993174	-4,0970362	-3,6879867	-3,2811592	-4,6003793	-1,4470401	-4,3747603	-3,2401856	-2,3268512
7 Костромская область	-4,8788033	-6,2343343	-8,7634658	-5,8296173	-7,7936745	-9,4053134	-8,311186	-6,4613598	-2,5433906	-5,5777971	-5,805135	-2,3241933
8 Курская область	-4,5929088	-5,9608338	-6,042993	-6,6711808	-5,7036111	-6,9453361	-4,2313061	-7,0127926	-2,6056725	-6,3398644	-13,815511	-2,3181096
9 Липецкая область	-4,1776453	-5,5687994	-7,729392	-6,0913624	-7,056294	-7,9854963	-10,012794	-2,9981192	-2,2337698	-2,8971919	-13,815511	-2,3158547
10 Московская область	-2,7828819	-2,963629	-3,6724032	-4,1349962	-1,5967085	-1,6737416	-1,1262684	-3,7760818	-0,5692753	-1,8451585	-2,3086274	-2,1184948

Рис. 2. Фрагмент матрицы данных для анализа

Fig. 2. Fragment of the data matrix for analysis

После этого линеаризуются входные данные, т.е. берется от них натуральный логарифм. Точно также поступают с целевыми значениями (y_j). Таким образом, решается проблема зашумленных данных, что позволит провести более качественное ML модели. В результате все данные будут выглядеть так, как показано на рис. 2.

Этап 3 – выделение обучающей и верификационной выборки. Последний 2023 г. выборки оставляется для последующей верификации обученной модели. Саму модель обучаем на выборке с 2010 по 2022 г.

Этап 4 – обучение модели по обучающей выборке методами MARS, ANFIS-PSO, MLP, KNN. Результаты обучения оцениваются на тестовой выборке (test), индивидуальной для каждого метода, где предварительно вся обучающая выборка разделяется на train (обучение), test (тестирование) и иногда, как, например, в нейронной сети MLP, еще на validation (валидация).

Этап 5 – сравнение результатов верификации модели по данным 2023 г. Верификация проводится на основе выборки 2023 г. Для этого вычисляется MAPE для каждой из трех целей.

Этап 6 – определение регионов-лидеров и регионов, претендующих на лидерство. Здесь используются нормализованные фактические значения для всех трех целевых функций лишь в верифицируемом 2023 г. За счет нормализации они сравнимы между собой. Их наибольшие значения позволяют выбрать регионы-лидеры и регионы, претендующие на лидерство.

Этап 7 – обратный переход от линеаризованных данных к реальным. Чтобы в дальнейшем анализировать целевые предсказанные по обученной модели данные (y_j) для перечисленных регионов, необходимо сначала перейти обратно от их линеаризованных значений к нормализованным. Для этого берется экспонента от линеаризованных данных. После этого от полученных нормализованных данных переходят к реальным по формуле

$$y = \tilde{y}(y_{\max} - y_{\min}) + y_{\min},$$

где \tilde{y} – новое значение целевой переменной; y – старое значение целевой переменной; y_{\min} – ее минимальное значение; y_{\max} – ее максимальное значение.

Это позволяет прежде всего продолжить верификацию обученной модели по данным 2023 г.

Этап 8 – определение плановых сегментов по регионам-лидерам для входных переменных и целевых функций. Для фактических значений входных переменных и целевых функ-

ций в 2023 г. по регионам-лидерам определяются необходимые плановые сегменты.

Этап 9 – оценка соответствия плановым сегментам входных переменных и целевых функций для регионов, претендующих на лидерство. Здесь сравниваются фактические значения входных переменных и целевых функций в 2023 г. для регионов, претендующих на лидерство, со значениями для регионов-лидеров.

Этап 10 – оценка перспектив инновационного развития регионов, претендующих на лидерство в 2023 г. согласно наиболее качественной модели. В данном случае используется наиболее качественная модель из полученных согласно алгоритмам MARS, ANFIS-PSO, MLP или KNN. Это позволяет оценить, какие регионы из претендующих на лидерство имеют перспективы инновационного развития в отрасли РЭП.

Результаты

Опишем результаты, которые получаются, если применить представленный алгоритм.

Этап 1. Собираются данные о входных переменных (x_i) и значениях целевых функций (y_j), представленных на рис. 2, с сайта Федеральной службы государственной статистики (www.rosstat.gov.ru). В результате получается квазивременной ряд в виде матрицы данных размерности 1162×12 .

Этап 2. С сайта Банка России берутся данные годовой инфляции (www.cbr.ru) и умножаются на темпы инфляции (все данные приведены в рублях с 2010 по 2022 г.). Таким образом получают данные в ценах последнего 2023 г.

После этого нормализуются и линеаризуются входные данные, т.е. берется от них натуральный логарифм. Точно также поступают с целевыми значениями (y_j). В результате все данные будут выглядеть так, как показано на рис. 2.

Этап 3. Последний 2023 г. выборки оставляется для последующей верификации обученной модели. Саму модель обучают на выборке с 2010 по 2022 г.

Этап 4. Результаты обучения цели 1 методом KNN проиллюстрированы на рис. 3, а и б. При этом на рис. 3, а показано распределение остатков (residuals) от ошибки обученной модели. Наглядно видно, что оно близко к нормальному закону распределения, что следует оценить положительно. Кроме того, на рис. 3, б представлено соотношение наблюдаемых (observed) и предсказанных (predictions) значений на тесте (test). Значения почти ложатся на восходящую прямую. На основе этих двух графиков можно утверждать, что модель обучена качественно. То же самое проделано для целей 2 и 3, представленных на рис. 2.

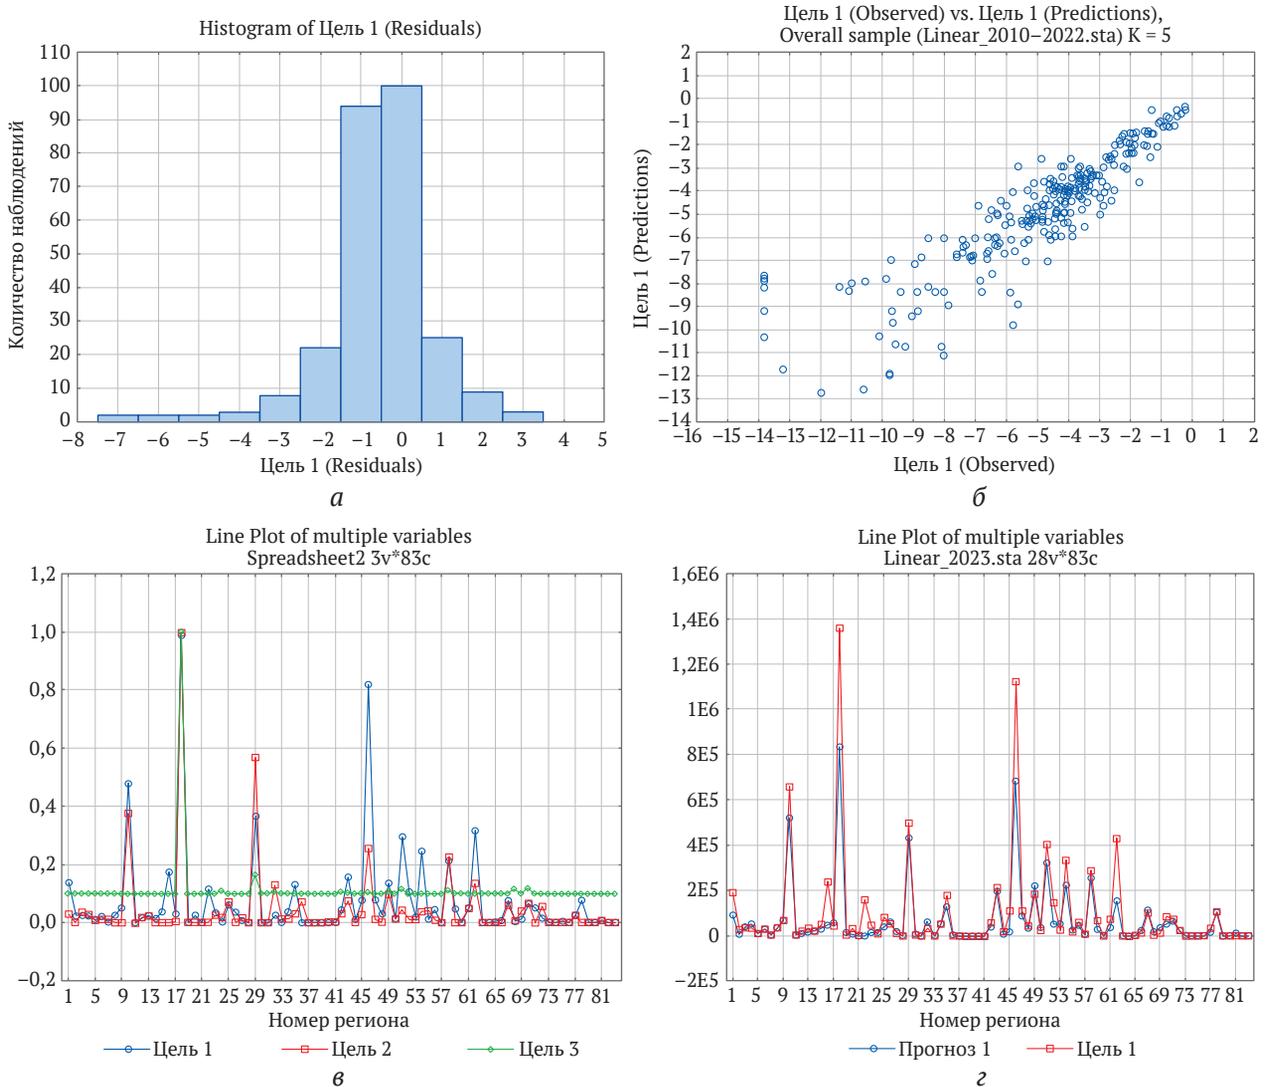


Рис. 3. Результаты обучения и верификации модели

Fig. 3. Model training and verification results

Этап 5. Оценивается MAPE для каждой из трех целей. Результаты всех используемых алгоритмов представлены в **табл. 1**, где жирным шрифтом отмечены лучшие значения для KNN и других алгоритмов, с которыми сравнивается KNN. Алгоритм KNN на этапе верификации превосходит три других, поэтому в дальнейшем будем ориентироваться на его результаты.

Проблемной является лишь цель 3, поскольку ее данные на всем периоде с 2010 по 2023 г. сильно зашумлены. Это отразилось и на ошибке MAPE на этапе верификации. Для целей 1 и 2 ошибка MAPE удовлетворительная.

Этап 6. На рис. 3, в представлены нормализованные фактические значения всех трех целевых функций в 2023 г. Наибольшие значения на

графике позволяют выбрать регионы–лидеры и регионы, претендующие на лидерство.

К регионам–лидерам относятся: регион 10 – Московская область, регион 18 – г. Москва, регион 29 – г. Санкт-Петербург и регион 46 – Республика Татарстан.

Таблица 1 / Table 1

Ошибка MAPE на этапе верификации

MAPE error at verification stage

Алгоритм	Цель 1	Цель 2	Цель 3
MARS	1,440687	1,001173	6,947672
ANFIS-PSO	1,612973	0,845674	155,89347
MLP	0,91006	1,185337	49,226858
KNN	0,822648	0,695549	6,812221

К регионам, претендующим на лидерство, относятся: регион 1 – Белгородская область, регион 16 – Тульская область, регион 25 – Ленинградская область, регион 32 – Краснодарский край, регион 35 – Ростовская область, регион 43 – Республика Башкортостан, регион 49 – Пермский край, регион 51 – Нижегородская область, регион 54 – Самарская область, регион 58 – Свердловская область, регион 62 – Челябинская область и регион 70 – Новосибирская область.

Этап 7. Обратный переход от линеаризованных данных к реальным позволяет прежде всего продолжить верификацию обученной модели по данным 2023 г. Так, к примеру, для цели 1 результаты представлены рис. 3, где ее фактические значения сравниваются с прогнозными. Прогнозные значения почти соответствуют фактическим. Подобные качественные прогнозы получаются также для целей 2 и 3.

Этап 8. В табл. 2 для фактических значений входных переменных и целевых функций в 2023 г. по регионам-лидерам определяются необходимые плановые сегменты, т.е. худшие значения и лучшие, выделенные курсивом.

Этап 9. Жирным шрифтом в табл. 2 отмечены значения, которые соответствуют плановым сегментам. То есть регионами, реально претендующими на лидерство в будущем, на данном этапе по входным переменным являются прежде всего Краснодарский край, а также Нижегородская и Свердловская область. Затем идут Пермский край, Челябинская и Новосибирская область. Попадание их входных параметров в плановые сегменты может способствовать инновационному развитию отрасли РЭП в указанных регионах.

По фактическим значениям целевых функций регионов, реально претендующих на лидерство, нет за исключением результатов по целевой функции 3, которая сильно зашумлена, поэтому ориентироваться на ее фактические значения нецелесообразно.

Этап 10. На этапе 5 было установлено, что наиболее качественная модель получена с помощью алгоритма KNN. По табл. 2 оценим, у каких регионов из претендующих на лидерство есть возможности инновационного развития в отрасли РЭП. Это регионы, для которых значения их прогнозных целевых функций попадают в плановые сегменты. При этом учитываются лишь те регионы, для которых полученный прогноз качественный, т.е. ошибка MAPE < 0,5. Это Краснодарский и Пермский край, Нижегородская, Свердловская, Челябинская, Новосибирская область. Они отмечены в табл. 2 жирным шрифтом.

Отметим отдельно, что если выполнить подобный анализ для алгоритмов MARS, ANFIS-PSO, MLP, выбирая соответствующий наилучший из них в табл. 1, где MARS применяем для цели 3, ANFIS-PSO – для цели 2 и MLP – для цели 1, то получается, что из претендующих на лидерство возможности инновационного развития в отрасли РЭП имеют Нижегородская и Свердловская область, что частично подтверждает выводы, которые были получены с использованием алгоритма KNN.

Заключение

Масштабирование предложенной модели на другие отрасли промышленности возможно, так как несмотря на то, что модель строится для отрасли РЭП, она также характеризует, как данная отрасль влияет на инновационное развитие и других отраслей промышленности – по целевым функциям 1 и 2. В этом выражается ее преимущество. При этом в качестве целевой функции 3 можно принять сальдированный финансовый результат соответствующей отрасли.

В заключении зафиксируем основные выводы проведенного исследования.

1. Технологии ML являются достаточно мощным инструментом анализа Big Data, а потому могут быть применены для оценки перспектив инновационного развития РЭП в регионах страны. Для этого применяется метод KNN, нейронные сети MLP и ANFIS-PSO, а также алгоритм MARS, чтобы затем сравнить результаты качества прогнозирования разными методами и выбрать наиболее оптимальный.

2. В качестве целевых функций рассмотрены цели: 1 – объем инновационных товаров; 2 – разработанные передовые производственные технологии; 3 – сальдированный финансовый результат (информатизация и связь). Модель обучалась на выборке с 2010 по 2022 г. для 83 регионов России. Последний 2023 г. выборки оставляется для последующей верификации обученной модели.

3. В работе установлено, что наиболее качественный прогноз позволяет получить алгоритм KNN, с помощью которого оценивается, какие регионы из претендующих на лидерство имеют перспективы инновационного развития в отрасли РЭП, т.е. регионы, у которых значения прогнозных целевых функций попадают в плановые сегменты в 2023 г. При этом учитываются лишь те регионы, для которых прогноз качественный, т.е. ошибка MAPE < 0,5. Это Краснодарский, Пермский край, Нижегородская, Свердловская, Челябинская, Новосибирская область.

Таблица 2 / Table 2

Оценка перспектив инновационного развития регионов в отрасли радиоэлектронной промышленности
Assessment of prospects for innovative development of regions in the electronic industry

Регионы	Вход 1 – Стоимость ОФ (информатизация и связь), млн руб.	Вход 2 – Ввод в действие ОФ (информатизация и связь), млн руб.	Вход 3 – Оборот организаций (информатизация и связь), млрд руб.	Вход 4 – Затраты на внедрение и использование цифровых технологий (всего), млн руб.	Вход 5 – Внутренние текущие затраты на НИР (фундаментальные и исследовательские), млн руб.	Вход 6 – Внутренние текущие затраты на НИР (прикладные и следования), млн руб.	Вход 7 – Внутренние затраты на НИР (разработки), млн руб.	Вход 8 – Затраты на инновационную деятельность (всего), млн руб.	Вход 9 – Используемые производственные технологии (всего), ед.
Московская область	350796	32709	69	101571,1	18248	41934	121617,4	235330,9	18528
г. Москва	3581621	608893	6327,4	2536455,6	104360,3	122356,2	310814,2	1272110,7	17097
г. Санкт-Петербург	428698	43823	789,2	281531,3	25456,4	29022,7	117545,4	184337,1	14710
Республика Татарстан	169777	17067	122,3	72377,7	3517,3	5300	21214,5	314910,8	7668
Худшее значение	169777	17067	69	72377,7	3517,3	5300	21214,5	184337,1	7668
Лучшее значение	3581621	608893	6327,4	2536455,6	104360,3	122356,2	310814,2	1272110,7	18528
Белгородская область	28011	1660	10,1	14013	1063,5	1536,9	1513,1	20041,2	3382
Тульская область	29746	1860	1,4	9354,3	303,6	1271,3	6525,2	45268,5	3886
Ленинградская область	40741	2691	3,3	14565	588,1	3352,7	7062,1	47787,1	3224
Краснодарский край	197076	20191	27,5	41207	3844,1	2972,7	1241	40142,2	5294
Ростовская область	115774	9394	3,2	21820,8	2669	3417,2	9389,5	55618,4	5525
Республика Башкортостан	86386	4920	27,9	35703,9	2680	2507,1	9116,1	34664,3	8352
Пермский край	76496	6348	62,5	37085,4	1588,1	2060	20710,9	75432,8	16504
Нижегородская область	150993	15804	40,6	54140,6	5093,5	17381,6	83799,8	145649,5	9030
Самарская область	114906	6343	7,3	42540,3	1094,4	2080,1	20826,3	82220,3	7563
Свердловская область	243704	14341	71,7	62215,1	6214,6	7520,7	23609,5	74533,4	15732
Челябинская область	89358	3593	10,7	36083,9	963,9	1359,5	21267,7	33096,7	8441
Новосибирская область	146532	9858	60,5	58894,5	17161,6	7340	12699	24281,3	3784

Окончание табл. 2 / Eng of Table 2

Регионы	Цель 1 – Объем инновационных товаров (всего), млн руб.	Прогноз 1	МАРЕ 1	Цель 2 – Разработанные передовые производственные технологии (всего), ед.	Прогноз 2	МАРЕ 2	Цель 3 – Сальдированный финансовый результат (информатизация и связь), млн руб.	Прогноз 3	МАРЕ 3
Московская область	657305,5	520402,202	0,208279557	251	154,879246	0,382951213	149	21821,9425	145,45599
г. Москва	1358949,5	832914,916	0,387089133	664	226,84302	0,658368946	809410	611587,86	0,244402887
г. Санкт-Петербург	499661,7	429916,011	0,139585821	378	200,337396	0,470006889	61048	37145,836	0,391530664
Республика Татарстан	1126201,7	685555,148	0,391267881	169	53,9032049	0,681046125	2447	4830,6774	0,974122354
<i>Худшее значение</i>	<i>499661,7</i>	<i>429916,011</i>	<i>KNN</i>	<i>169</i>	<i>53,9032049</i>	<i>KNN</i>	<i>149</i>	<i>4830,6774</i>	<i>KNN</i>
<i>Лучшее значение</i>	<i>1358949,5</i>	<i>832914,916</i>	<i>KNN</i>	<i>664</i>	<i>226,84302</i>	<i>KNN</i>	<i>809410</i>	<i>611587,86</i>	<i>KNN</i>
Белгородская область	192562,6	91238,8434	0,526186064	21	33,2977048	0,585604992	608	1978,6764	2,25440197
Тульская область	237156,5	156388,406	0,340568757	0	3,05136206	–	389	286,8114	0,26269563
Ленинградская область	81918,6	54336,1895	0,336705101	48	21,1080639	0,560248669	127	34,1773953	0,730886651
Краснодарский край	33826,9	45898,9245	0,356876464	88	10,9243281	0,875859908	4993	5545,0204	0,110558862
Ростовская область	181793,2	128402,446	0,2936895	22	22,7838855	0,0356311584	519	294,3308	0,452888652
Республика Башкортостан	215542	185147,563	0,140216199	50	47,8966816	0,0420663682	3781	4566,4242	0,207729225
Пермский край	186460,6	181704,05	0,0255096786	65	69,0239096	0,0619063016	4985	1637,0808	0,671598636
Нижегородская область	406091,9	320676,814	0,210334374	30	20,7104944	0,309650187	13622	7848,25301	0,423854573
Самарская область	335142,8	223388,037	0,333454167	25	62,4556616	1,49822646	1243	1031,232	0,170368463
Свердловская область	290994,2	256336,443	0,119101194	148	115,783168	0,217681296	10165	6689,0434	0,341953428
Челябинская область	432180,1	155703,591	0,639725219	90	118,421637	0,315795962	1341	-320,1116	1,23871111
Новосибирская область	84246,3	85113,1343	0,0102892863	44	88,6033963	1,01371355	17701	10832,2328	0,38804402

4. Если выполнить подобный анализ для алгоритмов MARS, ANFIS-PSO, MLP, выбирая соответствующий наилучший из них, где MARS применяется для цели 3, ANFIS-PSO – для цели 2 и MLP – для цели 1, то получается, что из претендующих на лидерство перспектив инновационного развития в отрасли РЭП имеют Нижегородская и Свердловская область, что частично подтверждает выводы, полученные с помощью KNN.

В дальнейших исследованиях можно предложить следующий сценарий стратегирования инновационного развития любой отрасли промышленности регионов в зависимости от их групповой принадлежности.

Инновационный рейтинг регионов страны строится по тем же трем целевым функциям. Сам инновационный рейтинг подразумевает деление регионов на три класса: А – регионы-лидеры, В –

регионы со средним уровнем инновационного развития, С – депрессивные регионы. Построение и применение обозначенного инновационного рейтинга регионов подразумевает применение ML, а именно, решение задачи классификации с использованием алгоритма ансамбля «решающих деревьев», и далее – верификация полученных рейтингов на данных нового периода наблюдения в целях определения по регионам-лидерам сегментов входных переменных модели. Эти сегменты будут плановыми показателями для того, чтобы в дальнейшем определить, будет ли регион иметь инновационный рейтинг А либо другие соответствующие рейтинги.

Результаты исследования могут быть полезны государственным структурам в целях поддержки инновационно развивающихся регионов в отрасли РЭП.

Список литературы / References

1. Гринев С.А., Квинт В.Л. Формирование стратегических приоритетов промышленного развития РФ как инновационный фактор преодоления кризисных периодов. *Экономика промышленности*. 2023;16(3):275–283. <https://doi.org/10.17073/2072-1633-2023-3-275-283>
Grinev S.A., Kvint V.L. Formation of strategic priorities of industrial development of the Russian Federation as an innovative factor in overcoming crisis periods. *Russian Journal of Industrial Economics*. 2023;16(3):275–283. (In Russ.). <https://doi.org/10.17073/2072-1633-2023-3-275-283>
2. Яшин С.Н., Кошелев Е.В., Суханов Д.А. Эволюционное нейросетевое моделирование импортозамещения в радиоэлектронной промышленности регионов. *Финансы и кредит*. 2024;30(4):765–787. <https://doi.org/10.24891/fc.30.4.765>
Yashin S.N., Koshelev E.V., Sukhanov D.A. Evolutionary neural network modeling of import substitution in the electronics industry of regions. *Finance and Credit*. 2024;30(4):765–787. (In Russ.). <https://doi.org/10.24891/fc.30.4.765>
3. Yoosefzadeh-Najafabadi M., Earl Hugh J., Tulpan D., Sulik J., Eskandari M. Application of machine learning algorithms in plant breeding: Predicting yield from hyperspectral reflectance in soybean. *Frontiers in Plant Science*. 2021;11:2169. <https://doi.org/10.3389/fpls.2020.624273>
4. Ramezanpour A., Beam A.L., Chen J.H., Mashaghi A. Statistical physics for medical diagnostics: Learning, inference, and optimization algorithms. *Diagnostics*. 2020;10(11):972. <https://doi.org/10.3390/diagnostics10110972>
5. Okolie J.A., Savage Sh., Ogbaga C.C., Gunes B. Assessing the potential of machine learning methods to study the removal of pharmaceuticals from wastewater using biochar or activated carbon. *Total Environment Research Themes*. 2022;1-2:100001. <https://doi.org/10.1016/j.totert.2022.100001>
6. Jaiswal A., Babu A.R., Zadeh M.Z., Banerjee D., Makedon F. A survey on contrastive self-supervised learning. *Technologies*. 2021;9(1):2. <https://doi.org/10.3390/technologies9010002>
7. Fleer S., Moringen A., Klatzky R.L., Ritter H. Correction: Learning efficient haptic shape exploration with a rigid tactile sensor array. *PLoS One*. 2020;15(2):e0230054 <https://doi.org/10.1371/journal.pone.0230054>
8. Piryonesi S.M., El-Diraby T.E. Role of data analytics in infrastructure asset management: Overcoming data size and quality problems. *Journal of Transportation Engineering, Part B: Pavements*. 2020;146(2):04020022.
9. Uddin S., Haque I., Lu H., Moni M.A., Gide E. Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction. *Scientific Reports*. 2022;12:6256. <https://doi.org/10.1038/s41598-022-10358-x>
10. Halder R.K., Uddin M.N., Uddin M.A., Aryal S., Khraisat A. Enhancing K-nearest neighbor algorithm: A comprehensive review and performance analysis of modifications. *Journal of Big Data*. 2024;11:113. <https://doi.org/10.1186/s40537-024-00973-y>
11. Xiong L., Yao Y. Study on an adaptive thermal comfort model with K-nearest-neighbors (KNN) algorithm. *Building and Environment*. 2021;202:108026. <https://doi.org/10.1016/j.buildenv.2021.108026>
12. Patchanok S., Korn S. Random kernel k-nearest neighbors regression. *Frontiers in Big Data*. 2024;7:1402384. <https://doi.org/10.3389/fdata.2024.1402384>

13. Zardini E., Blanzieri E., Pastorello D. A quantum k-nearest neighbors algorithm based on the Euclidean distance estimation. *Quantum Machine Intelligence*. 2024;6:23. <https://doi.org/10.1007/s42484-024-00155-2>
14. Boateng E., Otoo J., Abaye D. Basic tenets of classification algorithms K-nearest-neighbor, support vector machine, random forest and neural network: A review. *Journal of Data Analysis and Information Processing*. 2020;08(04):341–357. <https://doi.org/10.4236/jdaip.2020.84020>
15. Isabona J., Imoize A.L., Ojo S., Karunwi O., Kim Y., Lee C.-C., Li C.-T. Development of a multilayer perceptron neural network for optimal predictive modeling in urban microcellular radio environments. *Applied Sciences*. 2022;12(11):5713. <https://doi.org/10.3390/app12115713>
16. Rashedi K.A., Ismail M.T., Al Wadi S., Serroukh A., Alshammari T.S., Jaber J.J. Multi-layer perceptron-based classification with application to outlier detection in Saudi Arabia stock returns. *Journal of Risk and Financial Management*. 2024;17(2):69. <https://doi.org/10.3390/jrfm17020069>
17. Sagias V.D., Zacharia P., Tempeloudis A., Stergiou C. Adaptive neuro-fuzzy inference system-based predictive modeling of mechanical properties in additive manufacturing. *Machines*. 2024;12(8):523. <https://doi.org/10.3390/machines12080523>
18. Putra V.G.V., Mohamad J.N. Adaptive neuro-fuzzy inference systems (ANFIS) and artificial neural networks (ANNs) for optimizing electrospun PVA/TiO₂ fiber diameter. *The Journal of The Textile Institute*. 2022;114(10):1898–1908. <https://doi.org/10.1080/00405000.2022.2150954>
19. Qiao J., Wang G., Yang Z., Luo X., Chen J., Li K., Liu P. A hybrid particle swarm optimization algorithm for solving engineering problem. *Scientific Reports*. 2024;14:8357. <https://doi.org/10.1038/s41598-024-59034-2>
20. Tang K., Meng C. Particle swarm optimization algorithm using velocity pausing and adaptive strategy. *Symmetry*. 2024;16(6):61. <https://doi.org/10.3390/sym16060661>
21. Adnan R.M., Liang Z., Heddami S., Zounemat-Kermani M., Kisi O., Li B. Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs. *Journal of Hydrology*. 2020;586:124371. <https://doi.org/10.1016/j.jhydrol.2019.124371>
22. Hwaidi A., Badr A., Henedy S., Ostrowski K., Imran H. Application of multivariate adaptive regression splines (MARS) approach in prediction of compressive strength of eco-friendly concrete. *Case Studies in Construction Materials*. 2022;17:e01262. <https://doi.org/10.1016/j.cscm.2022.e01262>

Информация об авторах

Сергей Николаевич Яшин – д-р экон. наук, профессор, зав. кафедрой менеджмента и государственного управления, Нижегородский государственный университет им. Н.И. Лобачевского, 603022, Нижний Новгород, просп. Гагарина, д. 23, Российская Федерация; e-mail: jashinsn@yandex.ru

Егор Викторович Кошелев – канд. экон. наук, доцент, Нижегородский государственный университет им. Н.И. Лобачевского, 603022, Нижний Новгород, просп. Гагарина, д. 23, Российская Федерация; e-mail: ekoshelev@yandex.ru

Алексей Андреевич Иванов – канд. экон. наук, доцент кафедры менеджмента и государственного управления Института экономики и предпринимательства, Нижегородский государственный университет им. Н.И. Лобачевского, 603022, Нижний Новгород, просп. Гагарина, д. 23, Российская Федерация; e-mail: alexey.iff@yandex.ru

Information about the authors

Sergey N. Yashin – Dr.Sci. (Econ.), Professor, Head of the Department of Management and Public Administration, National Research Lobachevsky State University of Nizhny Novgorod, 23 Gagarina Ave., Nizhni Novgorod 603950, Russian Federation; e-mail: jashinsn@yandex.ru

Egor V. Koshelev – PhD (Econ.), Associate Professor, National Research Lobachevsky State University of Nizhny Novgorod, 23 Gagarina Ave., Nizhni Novgorod 603950, Russian Federation; e-mail: ekoshelev@yandex.ru

Aleksey A. Ivanov – PhD (Econ.), Associate Professor of the Department of Management and Public Administration, National Research Lobachevsky State University of Nizhny Novgorod, 23 Gagarina Ave., Nizhni Novgorod 603950, Russian Federation; e-mail: alexey.iff@yandex.ru

Поступила в редакцию 27.01.2025; поступила после доработки 30.05.2025; принята к публикации 04.06.2025
Received 27.01.2025; Revised 30.05.2025; Accepted 04.06.2025