

УДК 338.27, 332.142

DOI: 10.17586/2310-1172-2025-18-3-98-112

Научная статья

Язык статьи – русский

Нейросетевое моделирование взаимосвязи инвестиционного потенциала российских регионов и их ESG рэнкинга

Д-р экон. наук, профессор **Киришин И.А.** kia1125@mail.ru

Д-р экон. наук, профессор **Кох И.А.** koch-mail@yandex.ru

Д-р экон. наук **Захматов Д.Ю.** z_dmitry@bk.ru

Высшая школа бизнеса Института управления, экономики и финансов

Казанского федерального университета

420008, Россия, Республика Татарстан, г. Казань, ул. Кремлевская, 18

Целью данной статьи является выявление, тестирование и оценка влияния ESG рэнкинга на инвестиционный потенциал российских регионов (субъектов РФ) на основе нейросетевого моделирования. В качестве статистической выборки были использованы данные 83 российских регионов за 2020 год. Был проведен кросс-региональный множественный регрессионный анализ с использованием моделей нейронной сети многослойного персептрона. Для выявления причинно-следственных связей между переменной инвестиционного потенциала и тремя регрессорами: ESG рэнкинг региона, инвестиционный риск региона и валовой региональный продукт – использовалось приложение регрессия (regression) аналитического программного пакета STATISTICA (StatSoft). Оценка качества и точности модели многослойного персептрона производилась посредством вычисления средней абсолютной процентной ошибки. Проведенные численные эксперименты показали, что метод нейросетевого моделирования доступен в реализации, не требует больших вычислительных мощностей и демонстрирует хорошую точность. В ходе нейросетевого моделирования нелинейной регрессии инвестиционного потенциала субъектов РФ была специфицирована достоверная модель MLP 3-4-1 с высокой точностью описывающая и предсказывающая целевую переменную -инвестиционный потенциал региона. Полученные результаты подтверждают выдвинутую в статье гипотезу: инвестиционный потенциал российских регионов в большей степени зависит от ESG фактора и в меньшей степени от инвестиционного риска региона и валового регионального продукта. Глобальный анализ чувствительности показал, что все построенные нейронные сети определяют ESG переменную как наиболее важную. Доказанный приоритет важности влияния ESG рэнкинга на инвестиционный потенциал региона может быть использован региональными властями для обоснования приоритетных направлений региональной политики повышения инвестиционной привлекательности субъектов Российской Федерации.

Ключевые слова: ESG-концепция, инвестиционная привлекательность региона, нейронные сети; многослойный персептрон, глобальный анализ чувствительности, программный пакет STATISTICA.

Ссылка для цитирования:

Киришин И.А., Кох И.А., Захматов Д.Ю. Нейросетевое моделирование взаимосвязи инвестиционного потенциала российских регионов и их ESG рэнкинга // Научный журнал НИУ ИТМО. Серия «Экономика и экологический менеджмент». 2025. № 3. С. 98-112. DOI: 10.17586/2310-1172-2025-18-3-98-112.

Scientific article

Article in Russian

Neural network modeling of the relationship between the investment potential of Russian regions and their ESG ranking

D.Sc., professor **Kirshin I.A.** kia1125@mail.ru

D.Sc., professor **Koch I.A.** koch-mail@yandex.ru

D.Sc. **Zakhmatov D.Yu.** z_dmitry@bk.ru

Graduate School of Business of the Institute of Management, Economics and Finance

Kazan Federal University

Kremlevskaya str., 18, Kazan, Republic of Tatarstan, 420008, Russia

The purpose of this article is to identify, test and evaluate the impact of ESG ranking on the investment potential of Russian regions (subjects of the Russian Federation) based on neural network modeling. The sample used was data from 83 Russian regions for 2020. A cross-regional multiple regression analysis was conducted using multilayer perceptron neural network models. To identify causal relationships between the investment potential variable and three regressors: regional ESG ranking, regional investment risk and Gross Regional Product, the regression application of the STATISTICA (StatSoft) analytical software package was used. The quality and accuracy of the multilayer perceptron regression model was assessed by calculating the Mean Absolute Percentage Error. The numerical experiments showed that the neural network modeling method is available in implementation, does not require large computing power and demonstrates good accuracy. In the course of neural network modeling of nonlinear regression of investment potential of the subjects of the Russian Federation, a reliable MLP 3-4-1 model was specified with high accuracy describing and predicting the target variable - the investment potential of the region. The results obtained confirm the hypothesis put forward in the article: the investment potential of Russian regions depends to a greater extent on the ESG ranking and to a lesser extent on the investment risk of the region and the Gross Regional Product. Global sensitivity analysis showed that all constructed neural networks define the ESG variable as the most important. The proven priority of the importance of the influence of the ESG ranking on the investment potential of the region can be used by regional authorities to justify priority areas of regional policy to increase the investment attractiveness of the subjects of the Russian Federation.

Keywords: ESG concept, investment attractiveness of the region, neural networks; multilayer perceptron, global sensitivity analysis, STATISTICA software package.

For citation:

Kirshin I.A., Koch I.A., Zakhmatov D.Yu. Neural network modeling of the relationship between the investment potential of Russian regions and their ESG ranking. *Scientific journal NRU ITMO. Series «Economics and Environmental Management»*. 2025. № 3. P. 98-112. DOI: 10.17586/2310-1172-2025-18-3-98-112.

Введение

Задачи повышения инвестиционной привлекательности регионов являются предметом пристального внимания многих исследователей. В данном контексте в публикациях рассматриваются теоретические аспекты проблем регионального неравенства [1], а также методы формирования и развития инвестиционного потенциала регионов [2].

Модели оценки инвестиционного потенциала включают, как правило, такие параметры, как валовой региональный продукт, уровень безработицы, средняя заработная плата, численность населения и потенциальная рабочая сила [3]. Параметры инвестиционного потенциала и инвестиционного риска регионов используются для составления рейтинга инвестиционной привлекательности регионов Российской Федерации в методике компании «РАЭК-Аналитика» [4]. В соответствии с данной методикой интегральный инвестиционный потенциал региона включает следующие составляющие: трудовой, производственный, потребительский, институциональный, инфраструктурный, природно-ресурсный, финансовый, туристический и инновационный потенциалы.

Отметим, что наряду с традиционными параметрами инвестиционной привлекательности регионов, особое внимание исследователей в последнее время как в мировой [5], так и в российской практике [6], уделяется исследованию роли ESG-факторов (экологические, социальные и управленческие) в привлечении инвестиций на региональном уровне. Современные инвесторы всё чаще выбирают регионы, соответствующие принципам ESG. Устойчивое развитие перестало быть просто «трендом» – оно стало ключевым фактором долгосрочного экономического роста и инвестиционной привлекательности, что обусловлено аспектами, приведенными в таблице 1.

Мировая практика устойчивого инвестирования институциональных инвесторов в последние годы перешла от узкоспециализированной стратегии к подходу, обусловленному динамикой мирового рынка, геополитическими сдвигами и финансовыми стимулами. Значительная часть портфелей суверенных фондов благосостояния, пенсионных фондов и страховых компаний инвестируется в активы, ориентированные на окружающую среду, социальную сферу и управление (ESG). Применение норм ESG в мировой практике закреплено политикой многих национальных органов государственного управления, включая Регламент раскрытия информации об устойчивом финансировании (Sustainable Finance Disclosure Regulation, SFDR) Европейского союза, правительственные инициативы Китая в области зеленого финансирования и правила ESG Комиссии по ценным бумагам и биржам США [7]. Современные глобальные вызовы, такие, как пандемия COVID-19, привели институциональных инвесторов к пониманию важности инвестиционных приоритетов, балансирующих ответственное управление, устойчивое развитие социальной сферы и экологической среды.

Таблица 1

**Основные аспекты взаимосвязи инвестиционного потенциала регионов
и принципов устойчивого развития**

Фактор	Аспект	Пояснение
Экономическая устойчивость (E – Environmental)	Природные ресурсы и экология	Регионы с низким уровнем загрязнения, развитой "зелёной" энергетикой и эффективным управлением отходами привлекают ESG-ориентированных инвесторов
	Климатические риски	Инвесторы избегают регионов с высокими рисками наводнений, засух или других природных катастроф
	"Зелёные" технологии	Регионы, поддерживающие возобновляемую энергетику и эко-инновации, получают больше инвестиций в низкоуглеродные проекты
Социальная ответственность (S – Social)	Качество человеческого капитала	Доступность образования, уровень здравоохранения и социальной защиты повышают инвестиционную привлекательность
	Трудовые условия	Регионы с низким уровнем неравенства, соблюдением прав работников и высокой инклюзивностью привлекают ответственных инвесторов
	Социальная стабильность	Низкий уровень преступности, коррупции и социальных конфликтов снижает риски для бизнеса
Качество управления (G – Governance)	Эффективность госуправления	Прозрачность, низкий уровень коррупции и стабильное законодательство повышают доверие инвесторов
	Поддержка ESG-инициатив	Регионы с чёткими стратегиями устойчивого развития (например, углеродной нейтральности) привлекают больше "зелёных" инвестиций
	Правовая защита инвесторов	Защита прав собственности критически важны для долгосрочных вложений

Составлено авторами

В России принят ряд ключевых законов и стратегических документов относительно устойчивого развития, в том числе в отношении климатической политики и углеродного регулирования¹, «зелёного финансирования» и ESG-отчётности², социальной ответственности и корпоративного управления³, экологии и устойчивому развитию⁴. При этом наблюдается дефицит эмпирических исследований анализа влияния данных факторов на показатели инвестиционной привлекательности регионов, что и обусловило внимание авторов к данной тематике.

Исходя из вышеизложенных суждений, целью данного исследования является выявление, тестирование и оценка влияния ESG рэнкинга на инвестиционный потенциал российских регионов (субъектов РФ) на основе нейросетевого моделирования. Нейросетевое моделирование активно и успешно используется в экономических исследованиях [8, 9, 10]. Авторами настоящей статьи выдвигается следующая гипотеза исследования: высший приоритет по степени важности влияния на инвестиционный потенциал региона принадлежит ESG рэнкингу региона.

Данные и спецификация модели

Спецификация нейросетевой модели, идентифицирующей причинно-следственные связи между инвестиционным потенциалом региона и выбранными независимыми переменными, производилась на

¹ Федеральный закон от 02.07.2021 г. № 296-ФЗ «Об ограничении выбросов парниковых газов» [Электронный ресурс] https://www.consultant.ru/document/cons_doc_LAW_388992/ (дата обращения 12.05.2025)

² Положение Банка России от 19.12.2019 N 706-П (ред. от 04.03.2024) "О стандартах эмиссии ценных бумаг" [Электронный ресурс] https://www.consultant.ru/document/cons_doc_LAW_344933/ (дата обращения 12.05.2025)

³ "Письмо" Банка России от 27.12.2021 N ИН-06-28/102 "О раскрытии в годовом отчете публичного акционерного общества отчета о соблюдении принципов и рекомендаций Кодекса корпоративного управления" (вместе с "Рекомендациями по составлению отчета о соблюдении принципов и рекомендаций Кодекса корпоративного управления") [Электронный ресурс] https://www.consultant.ru/document/cons_doc_LAW_405380/ (дата обращения 12.05.2025)

⁴ Федеральный закон от 10.01.2002 № 7-ФЗ «Об охране окружающей среды» [Электронный ресурс] https://www.consultant.ru/document/cons_doc_LAW_34823/ (дата обращения 12.05.2025)

пространственной выборке, состоящей из данных 83 российских регионов за 2020 год. Факторы (предикторы модели), используемые в этом исследовании, были выбраны из доступных табличных показателей в соответствии с критерием сбалансированности данных за 2020 год. Выбор данного периода обусловлен соответствием критериям полноты информации для построения модели. Предложенная нами модель включает одну зависимую переменную - инвестиционный потенциал (Potential) [11] и три независимые переменные-предикторы регрессионной модели: ESG рэнкинг региона [12], инвестиционный риск региона (Risk) [13] и валовой региональный продукт (GRP) [14].

Традиционно, перед использованием искусственных нейронных сетей (ANNs) проводится специальная подготовка данных, включающая несколько процедур: "очистка" данных для устранения ошибок, обработка пропущенных значений, исправление выбросов и обеспечение соответствия типов переменных разных размерностей посредством их нормализации или стандартизации. Многочисленные эксперименты показали, что обычно ANNs работают лучше, когда характеристики входных данных представлены в сопоставимых масштабах. Предварительная обработка данных является одной из самых важных и сложных задач, главная цель которой - преобразовать необработанные данные в понятный формат, т.е. закодировать необработанные данные в форму, которую можно легко проанализировать и интерпретировать алгоритмом.

В исходном наборе данных наблюдаются большие диапазоны значений признака GRP. Поэтому перед ANN моделированием была проведена нормализация этих данных посредством масштабирования диапазона данных от нуля до единицы методом минимакс (1):

$$X_{norm} = (X - X_{\min}) / (X_{\max} - X_{\min}) \quad (1)$$

где X_{norm} – это выход признака X после нормализации, $X_{\min}$ и $X_{\max}$ – это минимум и максимум признака X .

Для проверки исследовательской гипотезы была выявлена и протестирована зависимость инвестиционного потенциала региона от вышеописанных признаков.

Изначально был проведен предварительный визуальный анализ выборки исходных данных посредством построения диаграмм рассеяния для визуализации распределения данных в трехмерном пространстве (рис. 1, 2, 3).




Рис. 1. Диаграмма рассеяния данных в осях инвестиционный потенциал, инвестиционный риск и ESG (построено авторами)




Рис. 2. Диаграмма рассеяния данных в осях инвестиционный потенциал, инвестиционный риск и GRP (построено авторами)




Рис. 3. Диаграмма рассеяния данных в осях GRP, инвестиционный риск и ESG (построено авторами)

Полученные 3D-изображения демонстрируют неслучайную структуру распределения данных, подчиняющееся некоторому закону. Визуально наблюдаются структурированные зависимости между парами предикторов ESG, Risk и целевой переменной, т.к. если переменные сильно связаны, то множество точек принимает определенную форму в пространстве. В то время как пространственное распределение значений

переменной GRP, характеризуется выбросами, что указывает на слабость потенциальных взаимосвязей между переменными. Если переменные не связаны, то точки образуют «облако рассеяния».

Выявленные визуально зависимости являются нелинейными, что предопределило применение подхода ANN для их моделирования, поскольку с его помощью возможно обрабатывать "шумные" нелинейные процессы. В этой статье используется подход ANN, основанный на нейронной сети многослойного персептрона (MLPNN), которая принадлежит к общему классу структур ANN, называемых нейронными сетями прямого распространения (FNN).

Для выявления причинно-следственных связей между переменной Potential и тремя регрессорами использовалось приложение регрессия (regression) аналитического программного пакета STATISTICA (StatSoft).

Были реализованы три стратегии построения моделей MLPNN (регрессия), предоставляемые пакетом STATISTICA:

1. Автоматизированная нейронная сеть.
2. Пользовательская нейронная сеть.
3. Метод многократных подвыборок.

Для всех трех стратегий были заданы следующие размеры подвыборок: для обучающей 70%; для контрольной 15%; для тестовой 15%. Подвыборки выбирались из общей выборки случайным образом. В методе многократных подвыборок величина обучаемых подвыборок была задана в количестве 5 подвыборок.

В данном исследовании оценка качества и точности модели регрессии MLP производилась посредством вычисления метрики средней абсолютной процентной ошибки (Mean Absolute Percentage Error, MAPE) (2), рассчитываемой как:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - \bar{x}_i|}{x_i} \cdot 100\% \quad (2)$$

где x_i обозначает наблюдаемое значение инвестиционного потенциала региона i , $\bar{x}_i$ обозначает прогнозируемое значение инвестиционного потенциала региона i (выходные данные модели). Согласно Витту, модели прогнозирования классифицируются как модели с высокой степенью точности, когда значение MAPE ниже 10% [15]. Если MAPE меньше 5%, то эффективность модели можно считать превосходной (excellent) [16].

Результаты и обсуждения

Рассмотрим результаты моделирования MLPNN с тремя входными переменными и одной выходной переменной по первой стратегии, посредством анализа пяти лучших из построенных MLPNN, ошибка на контрольной выборке у которых минимальна (таблица 2).

Таблица 2

Результаты обучения по первой стратегии «Автоматизированная нейронная сеть»

№ модели	Архитектура сети	Производительность обучения	Тестовая производительность	Контрольная производительность	Алгоритм обучения	Активация на скрытом слое	Активация выхода
1	MLP 3-5-1	0,972578	0,960878	0,985244	BFGS 14	Identity	Logistic
2	MLP 3-10-1	0,976380	0,933823	0,984925	BFGS 9	Exponential	Logistic
3	MLP 3-4-1	0,972672	0,962473	0,985824	BFGS 10	Identity	Logistic
4	MLP 3-8-1	0,972622	0,961560	0,985571	BFGS 10	Identity	Logistic
5	MLP 3-6-1	0,964119	0,958964	0,987867	BFGS 12	Tanh	Tanh

Для второй стратегии обучения «Пользовательская нейронная сеть» были заданы следующие параметры: функция активации на скрытом слое – гиперболическая, на выходном слое – тождественная. Также был задан

обучающий алгоритм второго порядка точности BFGS и количество эпох 2000. Результаты обучения по второй стратегии представлены в таблице 3.

Таблица 3

Результаты обучения по второй стратегии «Пользовательская нейронная сеть»

№ модели	Архитектура сети	Производительность обучения	Тестовая производительность	Контрольная производительность	Алгоритм обучения	Активация на скрытом слое	Активация выхода
6	MLP 3-4-1	0,973320	0,959109	0,980192	BFGS 26	Tanh	Identity
7	MLP 3-4-1	0,971464	0,957002	0,973633	BFGS 21	Tanh	Identity
8	MLP 3-4-1	0,971749	0,984451	0,981512	BFGS 33	Tanh	Identity
9	MLP 3-4-1	0,974119	0,961573	0,980623	BFGS 16	Tanh	Identity
10	MLP 3-4-1	0,977492	0,976929	0,980094	BFGS 31	Tanh	Identity

Результаты обучения по третьей стратегии методом многократных подвыборок представлены в таблице 4.

Таблица 4

Результаты обучения по третьей стратегии методом многократных подвыборок

№ модели	Архитектура сети	Производительность обучения	Тестовая производительность	Контрольная производительность	Алгоритм обучения	Активация на скрытом слое	Активация выхода
11	MLP 3-4-1	0,983031	0,992781	0,971627	BFGS 75	Tanh	Identity
12	MLP 3-4-1	0,970018	0,963696	0,969636	BFGS 17	Tanh	Identity
13	MLP 3-4-1	0,973347	0,982635	0,953700	BFGS 38	Tanh	Identity
14	MLP 3-4-1	0,986950	0,971651	0,995997	BFGS 95	Tanh	Identity
15	MLP 3-4-1	0,991559	0,979795	0,796506	BFGS 64	Tanh	Identity

Диаграмма рассеяния целевых и выходных значений для каждой из 15 построенных MLPNN (рис. 4) показала достаточно плотное распределение выходных значений вдоль прямой линии. В идеальном случае (если все выходы совпадут с целевыми значениями) все точки диаграммы рассеяния будут лежать на изображенной прямой линии – биссектрисе прямого угла.




Рис. 4. Диаграмма рассеяния целевых и выходных значений для каждой из 15 построенных MLPNN (построено авторами)

Проанализируем построенные 15 MLPNN по критерию максимума коэффициента детерминации на контрольной подвыборке (Validation performance). Наилучшей по данному критерию оказалась сеть № 14 «MLP 3-4-1» с коэффициентом детерминации 0,995997. Считается, если этот коэффициент выше 90%, модель имеет превосходную производительность. Значение коэффициента детерминации в диапазоне (0,82; 0,90) обычно означает хорошую производительность [17, 18].

Из полученных результатов построения MLPNN показателей инвестиционного потенциала субъекта РФ следует, что точность построенной модели достаточно высока, допуская в процентном соотношении менее 1% ошибки правильной идентификации на кросс-валидационной выборке.

Анализ графика гистограммы распределения остатков MLP 3-4-1 показал близкое к нормальному распределение остатков (рис. 5).




Рис. 5. Гистограмма распределения остатков MLP 3-4-1(построено авторами)

Далее для выбранной MLPNN была построена поверхность отклика с использованием двух регрессоров и переменной выхода, показывающая, насколько хорошо лучшая MLP 3-4-1 распознаёт зависимость между важными входами, в нашем случае между ESG и Risk и выходом Potential по точкам трехмерной диаграммы рассеяния (рис. 6).

Поверхность отклика позволяет выявить скрытую структуру данных и взаимосвязи между тремя переменными. С помощью экспериментов с вращением поверхностей, возможных в пакете Statistica, можно обнаружить сложные нелинейные взаимосвязи между переменными.




Рис. 6. Поверхность отклика MLP 3-4-1 (построено авторами)

Наглядно видно, что поверхность отклика выбранной MLP 3-4-1 хорошо аппроксимирует исходные данные диаграммы рассеяния, что определяет достаточный уровень распознавания зависимости и говорит о хорошем качестве выбранной MLPNN. Однако, общеизвестно, что объективно нельзя однозначно ответить на вопрос, возможно ли повысить точность моделирования ANN. Обычно исследователь руководствуется простым правилом: если результаты нейросетевого моделирования для него приемлемы, то дальнейшее улучшение качества аппроксимации не проводится.

Далее, после обучения модели в пакете STATISTICA проводился анализ чувствительности в двух версиях: глобальный и локальный. Глобальный анализ чувствительности (Global sensitivity analysis) позволяет сделать вывод об относительной важности входных переменных для ANN и при необходимости удалить входы с низким показателем значимости. Процедура глобального анализа чувствительности показывает, какие входные переменные имеют наиболее важный вклад в ANN. Глобальный анализ чувствительности является статистическим методом анализа эффектов относительного изменения выходных значений модели при изменении входных параметров в определенном конечном диапазоне.

Проведенный глобальный анализ чувствительности (анализ важности входных переменных), подтверждает выдвинутую гипотезу: для каждой построенной MLPNN первое место по значимости занимает переменная ESG. На втором месте находится переменная инвестиционный риск региона, и последнее третье место занимает валовой региональный продукт (таблица 5).

Соответственно, именно обращение к признаку ESG рэнкинга позволяет в наибольшей степени раскрыть инвестиционный потенциал региона, в отличие от более привычных признаков инвестиционного риска и валового регионального продукта. Данный факт может указывать на определенную неполноту сформировавшейся модели факторного анализа и сложившейся понятийной практики регионального

инвестиционного анализа, которые аргументируются доминированием традиционных подходов исследователей в сфере факторного анализа региональной экономики.

Помимо этого, можно констатировать, что исходный датасет сгенерировал высокую надежность и качество полученной MLPNN, а также выявил значимые корреляционные связи переменных, что может послужить основой для использования этих признаков в других методиках регионального инвестиционного анализа. Не менее важен, по нашему мнению, результат проведенного ANN моделирования, продемонстрировавший низкую значимость вклада переменной GRP в региональный инвестиционный потенциал.

Объяснение этого феномена может быть двоякое. Либо GRP, действительно, «шумовая» переменная, влиянием которой можно пренебречь. Либо полученный результат обусловлен некоторыми ограничениями исследуемого датасета. Вероятно, используемое число наблюдений не позволяет объективно оценить влияние GRP на Potential. Поэтому данный эмпирически полученный результат требует проведения дальнейших исследований.

Таблица 5

Глобальный анализ чувствительности на обучающей подвыборке

№ модели и архитектура сети	ESG	Risk	GRP
1.MLP 3-5-1	23,31238	1,069948	1,010447
2.MLP 3-10-1	27,23985	1,049150	0,991006
3.MLP 3-4-1	23,27614	1,069606	1,009320
4.MLP 3-8-1	23,30635	1,058659	1,009511
5.MLP 3-6-1	16,92392	1,575650	0,977982
6.MLP 3-4-1	24,05719	1,107325	1,008355
7.MLP 3-4-1	23,39552	1,288689	1,008805
8.MLP 3-4-1	20,93193	1,150484	1,005285
9.MLP 3-4-1	30,36561	1,751115	1,158924
10.MLP 3-4-1	35,16874	3,059051	1,124056
11.MLP 3-4-1	31,55345	1,167004	2,097835
12.MLP 3-4-1	20,84602	1,503146	1,005707
13.MLP 3-4-1	23,08629	1,215938	0,995554
14.MLP 3-4-1	49,73552	1,218329	2,610764
15.MLP 3-4-1	75,17792	1,127468	1,347281
Среднее значение	29,89179	1,360771	1,224056

Схематично глобальный анализ работает следующим образом. В процессе анализа «отключается» поочередно каждая входная переменная. Далее общая ошибка ANN с отключенной переменной делится на ошибку ANN с включенной переменной, и результат деления сравнивается с единицей. Если результат больше единицы, то переменная вносит вклад в зависимую переменную, в противном случае ANN функционирует лучше без этой переменной, и следовательно, отключенную переменную можно удалить.

Второй версией анализа чувствительности, реализованной в пакете STATISTICA, является локальный анализ чувствительности, показывающий для каждой ANN знак (положительный или отрицательный) изменения выходной переменной при изменении входной переменной и, таким образом, описывающий поведение полученных графиков поверхностей отклика (таблица 6).

Таблица 6

Локальный анализ чувствительности

Точки сетки	Risk Чувствительность	ESG Чувствительность	GRP Чувствительность
Minimum	-3,30002	-0,100908	0,554091
2	-4,67299	-0,193929	0,041059
3	-6,09379	-0,356404	-0,419775
4	-7,45628	-0,394325	-0,777830
5	-8,61644	-0,154150	-0,980391
6	-9,40033	0,025159	-0,979430
7	-9,62283	0,029542	-0,739278
8	-9,11700	-0,011793	-0,243488
9	-7,76930	-0,041429	0,500876
Maximum	-5,55202	-0,056250	1,462781

Положительные табличные значения означают, что целевая переменная возрастает при увеличении соответствующего предиктора, и, наоборот.

Рассмотрим качество выбранной модели №14. MLP 3-4-1 на тестовой подвыборке (таблица 7). Для этого оценим в таблице предсказанных значений абсолютные остатки.

Таблица 7

Предсказанные значения MLP 3-4-1 на тестовой подвыборке

№ наблюдения	Целевое значение переменной Potential	Выходное значение переменной Potential	Абсолютные остатки переменной Potential
(1)	(2)	(3)	Модуль ((3)-(2))
13	0,57500	0,589812	0,014812
32	0,74600	0,751329	0,005329
44	5,38800	5,378656	0,009344
51	0,56900	0,367273	0,201727
56	0,52300	0,554003	0,031003
60	1,87200	1,878178	0,006178
62	1,71300	1,702851	0,010149
66	12,48700	12,453536	0,033464
68	0,65300	0,687132	0,034132
70	8,65200	8,690004	0,038004
80	7,53200	7,524957	0,007043
83	7,43600	7,457286	0,007043

Качество MLP 3-4-1 на тестовой подвыборке оценивалось по критерию MAPE. Полученное значение MAPE для нашей ограниченной подвыборки, равное 3,32%, говорит об отличной эффективности выбранной модели.

Полученные результаты показывают, что MLP 3-4-1 рационально оценила инвестиционный потенциал региона. Таким образом, несмотря на ограниченность исходной выборки, MLP 3-4-1 смогла обучиться предсказывать рациональные результаты.

Построенная модель MLP 3-4-1 идентифицировала разнонаправленное влияние ESG рэнкинга на инвестиционный потенциал региона, визуально прослеживаемое на повернутой диаграмме поверхности отклика (рис. 7а и 7b).




Рис. 7а. Повернутая поверхность отклика MLP 3-4-1 (построено авторами)




Рис. 7b. Повернутая поверхность отклика MLP 3-4-1 (построено авторами)

При движении вдоль оси ESG в направлении возрастания ESG рэнкинга (на графике поверхности отклика справа налево) наблюдается сначала снижение инвестиционного потенциала региона до уровня ESG = 60, а затем возрастание. Возможно, это тот случай, когда сеть нашла зависимость, выявить которую логическим образом невозможно. Этот феномен получил название в публикациях по нейронным сетям «интуиция нейронных сетей» [19].

Меняющиеся рэнкинги ESG и различные нормативные базы оценки ESG рэнкинга в разных регионах не способствуют росту инвестиционной привлекательности регионов. Помимо этого, соблюдение ESG норм часто требует крупных первоначальных инвестиций, обучения персонала и трансформации корпоративных политик. В условиях высоких текущих рисков эффективности институциональные инвесторы могут отказаться от инвестиций даже с учетом будущих выгод, получаемых от ESG. Решение этих задач, по нашему мнению, лежит в области формирования аналитики ESG на основе достижений искусственного интеллекта и ANN, создающими доказательную базу управления рисками, связанными с устойчивым развитием, и принятия оптимальных инвестиционных решений.

Заключение

В настоящей статье был проведен сравнительный анализ производительность MLPNN разной архитектуры для моделирования влияния ESG рэнкинга на инвестиционный потенциал российских регионов. Перед обучением MLPNN была проведена процедура предварительной обработки данных по GRP, которая нормализовала эти данные.

В целом проведенные численные эксперименты показали, что метод MLPNN моделирования не сложен в реализации, не требует больших вычислительных мощностей и демонстрирует хорошую точность.

В данной работе было проведено нейросетевое моделирование оценки влияния ESG рэнкинга российских регионов, инвестиционного риска и валового регионального продукта на инвестиционный потенциал российских регионов. В ходе нейросетевого моделирования нелинейной регрессии инвестиционного потенциала субъектов РФ была специфицирована достоверная модель MLP 3-4-1, с высокой точностью описывающая и предсказывающая целевую переменную.

При этом было обнаружено, что для прогнозирования инвестиционного потенциала субъектов РФ, наиболее значимым является ESG рэнкинг, затем по важности следует инвестиционный риск и замыкает тройку предикторов валовой региональный продукт, как наименее значимый. Разработанные модели предоставляют региональным властям субъектов Российской Федерации возможность оценки ключевых показателей инвестиционной привлекательности регионов, оперативно диагностировать появляющиеся дисбалансы и принимать решения по их урегулированию, что способствует повышению эффективности региональной политики на мезоуровне национальной экономической системы России.

Литература

1. Беляева О.И. Стратегические приоритеты государственной политики в снижении регионального неравенства // Экономика и предпринимательство. 2021. № 10(135). С. 481–484. DOI 10.34925/EIP.2021.135.10.092.
2. Двас Г.В., Цыплакова Е.Г., Саргсян М.В. Инвестиционный потенциал региона и методы управления его формированием и развитием // Теория и практика общественного развития. 2023. № 6(182). С. 117–124. DOI 10.24158/tipor.2023.6.14.
3. Бэй Г. Оценка инвестиционного потенциала в российских регионах // Первый экономический журнал. 2024. № 9(351). С. 82–86. DOI 10.58551/20728115_2024_9_82.
4. Методика составления рейтинга инвестиционной привлекательности регионов России компании «РАЭК-Аналитика». [Электронный ресурс] https://raex-rr.com/regions/investment_appeal/investment_potential_of_regions/2020/methods/ (дата обращения 21.05.2025).
5. OECD (2022), 2022 Synthesis Report World Observatory on Subnational Government Finance and Investment, OECD Publishing, Paris. DOI:10.1787/b80a8cdb-en.
6. Измайлов М.К., Пупенцова С.В. ESG-трансформация в России как инструмент стратегического развития // Научный журнал НИУ ИТМО. Серия: Экономика и экологический менеджмент. 2024. № 4. С. 105–115. DOI 10.17586/2310-1172-2024-17-4-105-115.
7. Institutional investors and ESG worldwide – statistics & facts. [Электронный ресурс] <https://www.statista.com/topics/13428/institutional-investors-and-esg-worldwide/#topicOverview> (дата обращения 14.05.2025).
8. Abhiram Dash, Debasis Bhattacharya, Digvijay Singh Dhakre, Madhuchhanda Kishan (2022) On Selection of Best Model from Spline Regression and ARIMA Models for Forecasting Rabi Food Grain Production of Odisha // Environment and Ecology. 40(3B). pp. 1428–1437.
9. Mateus B.C., Mendes M., Farinha J.T., Cardoso A.J.M., Assis R., da Costa L.M. (2023) Forecasting Steel Production in the World // Assessments Based on Shallow and Deep Neural Networks. Appl. Sci. 13, 178. DOI: 10.3390/app13010178.

10. Захматов Д.Ю., Киришин И.А., Кох И.А. Построение финансовых временных рядов с применением нейронных сетей в отношении прогнозных показателей предприятия // KANT. 2025. № 1(54). С. 51-62. DOI: 10.24923/2222-243X.2025-54.9.
11. Инвестиционный потенциал российских регионов в 2020 году. [Электронный ресурс] https://raex-rr.com/regions/investment_appeal/investment_potential_of_regions/2020/ (дата обращения 25.05.2025).
12. ESG-рейтинг субъектов РФ, 2020 год. [Электронный ресурс] https://raex-rr.com/ESG/ESG_regions/ESG_rating_regions/2020/ (дата обращения 25.05.2025).
13. Инвестиционный потенциал российских регионов в 2020 году. [Электронный ресурс] https://raex-rr.com/regions/investment_appeal/investment_potential_of_regions/2020/ (дата обращения 25.05.2025).
14. Социально-экономические показатели регионов России//Росстат; обработка «Если быть точным», 2023. Условия использования: Creative Commons BY 4.0. [Электронный ресурс] https://tochno.st/datasets/regions_collection (дата обращения 24.05.2025).
15. Witt S.F., Witt C.A. (1992) Modeling and Forecasting Demand in Tourism. London: Academic Press.
16. Box G.E.P., Jenkins G.M. and Reinsel G.C. (1994) Time Series Analysis; Forecasting and Control, 3rd ed., Prentice Hall, Englewood Cliff, New Jersey.
17. Williams P., Norris K. (2001) Near-infrared Technology: In the Agricultural and Food Industries. 2nd ed. USA: American Association of Cereal Chemists, St. Paul, Minn.
18. Cheng J.H., Sun D.W. (2015) Recent applications of spectroscopic and hyperspectral imaging techniques with chemometric analysis for rapid inspection of microbial spoilage in muscle foods // Compr Rev Food Sci F. Vol. 14. Issue 14. P. 478-490. DOI: 10.1111/1541-4337.12141
19. Ясницкий Л.Н. Введение в искусственный интеллект. –М.: Академия. 2005. 176 с.

References

1. Belyaeva O.I. Strategicheskie priority gosudarstvennoi politiki v snizhenii regional'nogo neravenstva // *Ekonomika i predprinimatel'stvo*. 2021. № 10(135). S. 481–484. DOI 10.34925/EIP.2021.135.10.092.
2. Dvas G.V., Tsyplakova E.G., Sargsyan M.V. Investitsionnyi potentsial regiona i metody upravleniya ego formirovaniem i razvitiem // *Teoriya i praktika obshchestvennogo razvitiya*. 2023. № 6(182). S. 117–124. DOI 10.24158/tipor.2023.6.14.
3. Bei G. Otsenka investitsionnogo potentsiala v rossiiskikh regionakh // *Pervyi ekonomicheskii zhurnal*. 2024. № 9(351). S. 82–86. DOI 10.58551/20728115_2024_9_82.
4. Metodika sostavleniya reitinga investitsionnoi privlekatel'nosti regionov Rossii kompanii «RAEKS-Analitika». [Elektronnyi resurs] https://raex-rr.com/regions/investment_appeal/investment_potential_of_regions/2020/methods/ (data obrashcheniya 21.05.2025).
5. OECD (2022), 2022 Synthesis Report World Observatory on Subnational Government Finance and Investment, OECD Publishing, Paris. DOI:10.1787/b80a8cdb-en.
6. Izmailov M.K., Pupentsova S.V. ESG-transformatsiya v Rossii kak instrument strategicheskogo razvitiya // *Nauchnyi zhurnal NIU ITMO. Seriya: Ekonomika i ekologicheskii menedzhment*. 2024. № 4. S. 105–115. DOI 10.17586/2310-1172-2024-17-4-105-115.
7. Institutional investors and ESG worldwide – statistics & facts. [Elektronnyi resurs] <https://www.statista.com/topics/13428/institutional-investors-and-esg-worldwide/#topicOverview> (data obrashcheniya 14.05.2025).
8. Abhiram Dash, Debasis Bhattacharya, Digvijay Singh Dhakre, Madhuchhanda Kishan (2022) On Selection of Best Model from Spline Regression and ARIMA Models for Forecasting Rabi Food Grain Production of Odisha // *Environment and Ecology*. 40(3B). pr. 1428–1437.
9. Mateus B.C., Mendes M., Farinha J.T., Cardoso A.J.M., Assis R., da Costa L.M. (2023) Forecasting Steel Production in the World // *Assessments Based on Shallow and Deep Neural Networks*. Appl. Sci. 13, 178. DOI: 10.3390/app13010178.
10. Zakhmatov D.Yu., Kirshin I.A., Kokh I.A. Postroenie finansovykh vremennykh ryadov s primeneniem neironnykh setei v otnoshenii prognoznykh pokazatelei predpriyatiya // KANT. 2025. № 1(54). S. 51-62. DOI: 10.24923/2222-243X.2025-54.9.
11. Investitsionnyi potentsial rossiiskikh regionov v 2020 godu. [Elektronnyi resurs] https://raex-rr.com/regions/investment_appeal/investment_potential_of_regions/2020/ (data obrashcheniya 25.05.2025).
12. ESG-reiting sub"ektov RF, 2020 god. [Elektronnyi resurs] https://raex-rr.com/ESG/ESG_regions/ESG_rating_regions/2020/ (data obrashcheniya 25.05.2025).
13. Investitsionnyi potentsial rossiiskikh regionov v 2020 godu. [Elektronnyi resurs] https://raex-rr.com/regions/investment_appeal/investment_potential_of_regions/2020/ (data obrashcheniya 25.05.2025).

14. Sotsial'no-ekonomicheskie pokazateli regionov Rossii//Rosstat; obrabotka «Esli byt' tochnym», 2023. Usloviya ispol'zovaniya: Creative Commons BY 4.0. [Elektronnyi resurs] https://tochno.st/datasets/regions_collection (data obrashcheniya 24.05.2025).
15. Witt S.F., Witt C.A. (1992) Modeling and Forecasting Demand in Tourism. London: Academic Press.
16. Box G.E.P., Jenkins G.M. and Reinsel G.C. (1994) Time Series Analysis; Forecasting and Control, 3rd ed., Prentice Hall, Englewood Cliff, New Jersey.
17. Williams P., Norris K. (2001) Near-infrared Technology: In the Agricultural and Food Industries. 2nd ed. USA: American Association of Cereal Chemists, St. Paul, Minn.
18. Cheng J.H., Sun D.W. (2015) Recent applications of spectroscopic and hyperspectral imaging techniques with chemometric analysis for rapid inspection of microbial spoilage in muscle foods // *Compr Rev Food Sci F*. Vol. 14. Issue 14. P. 478-490. DOI: 10.1111/1541-4337.12141
19. Yasnitskii L.N. Vvedenie v iskusstvennyi intellekt. –M.: Akademiya. 2005. 176 s.

Статья поступила в редакцию 17.06.2025
Принята к публикации 03.09.2025

Received 17.06.2025
Accepted for publication 03.09.2025