

# Разработка методики комплексной оценки и прогнозирования инновационного развития региона с использованием самоорганизующейся нейросети

Development a methodology for a comprehensive assessment and forecasting of the region's innovative development using a self-organizing neural network

doi 10.26310/2071-3010.2020.261.7.009



**Л. А. Гамидуллаева,**

д. э. н., профессор, Пензенский государственный университет  
✉ gamidullaeva@gmail.com

**L. A. Gamidullaeva,**

doctor of economic sciences, professor, Penza state university

Цель данной статьи состоит в исследовании перспективных направлений использования технологий обработки экономической информации на основе нейросетевого моделирования для комплексной оценки и прогнозирования инновационного развития регионов.

Нейросетевой подход предполагает использование нейронных сетей, способных обучаться и обобщать накопленные знания, для решения задач классификации, идентификации и прогнозирования, что в конечном итоге позволяет объединить механизмы регулирования и самоорганизации в управлении региональными инновационными системами.

Автором предложено использовать самоорганизующиеся (эволюционирующие) нейронные сети. Использование принципов самоорганизации позволяет синтезировать многослойные нейронные сети на неполной, неrepresentative обучающей выборке. В результате исследования реализована общая концепция нейронной сети для решения прогностических задач в региональной инновационной системе, что является основой для разработки систем управления экономическим ростом субъектов РФ за счет инновационных факторов.

The purpose of this article is to study the opportunities that arise from the use of neural network data processing technologies for a comprehensive assessment and forecasting of the innovative development of regions.

The article substantiates the advantages of modeling using a neural network approach, which implies the use of neural networks that can learn and generalize accumulated knowledge to solve problems of classification, identification and forecasting. This ultimately allows you to combine the mechanisms of regulation and self-organization in the management of regional innovation systems.

The author proposed the use of self-organizing (evolving) neural networks. Using the principles of self-organization allows us to synthesize multilayer neural networks on an incomplete, non-representative training set. As a result of the study, the general concept of the neural network was implemented to solve prognostic tasks in the regional innovation system, which is the basis for the development of systems for managing the economic growth of the constituent entities of the Russian Federation due to the innovative factors.

**Ключевые слова:** инновации, алгоритм управления, методика оценки, нейросетевой подход, машинное обучение.

**Keywords:** innovation, control algorithm, assessment methodology, neural network approach, machine learning.

## Введение

Проблема ускорения экономического роста не нова для России, но на данный момент стоит как никогда остро. Темпы роста экономики нашей страны в среднесрочной перспективе, как официальными органами, так и различными исследовательскими группами оцениваются на уровне 2% [9]. При этом для достижения поставленной цели эти темпы должны превышать средние мировые, которые по различным оценкам составляют около 3%. Согласно классической экономической модели Кобба–Дугласа к основным факторам ВВП относятся труд, капитал и технология/производительность.

После бурного экономического роста, наблюдавшегося в РФ в 2000-х гг., последующего кризиса 2008 г., а затем замедленного роста и восстановления после кризиса 2014-2015 гг. мы наблюдаем снижение численности трудоспособного населения, что вполне коррелирует с общемировыми тенденциями, происходящее на фоне общей турбулентной экономической обстановки. При этом доступность капитала больше не является тем колоссальным конкурентным преимуще-

ством, которым она была в прошлом. Следовательно, из трех факторов роста ВВП, ставку можно делать лишь на один, и связан он с инновациями.

При этом является общепризнанным, что инновационный экономический рост должен быть запущен из регионов. Субъекты РФ как основной тип региона характеризуются неравномерностью развития различных аспектов инновационных процессов и влияющих на них внутренних и внешних факторов, демонстрируя в этом отношении существенное разнообразие. К таким факторам можно отнести финансовые и экономические условия, социальное расслоение, уровень доступного образования, наличие квалифицированных кадров, исторические аспекты развития, предпочтения и привычки населения, особенности места проживания и т. п. Следует признать, что существующая сегодня статистика не позволяет получать качественные достоверные данные о происходящих инновационных процессах на всех управленческих уровнях. А обработка этих данных традиционными методами еще больше снижает достоверность получаемых результатов.

В условиях цифровой трансформации экономики, когда требования к интеллектуализации систем

управления и поддержки принятия решений возрастают многократно, существует необходимость разработки междисциплинарных конструкторов в области исследования и управления инновационными экономическими процессами в субъектах РФ. Для выхода регионов на инновационную модель развития особую значимость приобретает формирование инновационно ориентированной системы стратегического управления и прогнозирования, включающей качественно новые методы, модели и механизмы, обеспечивающие научно обоснованное и аналитическое управление инновационными процессами.

Актуальность предлагаемого исследования подтверждается рядом обстоятельств:

- во-первых, недостаточностью междисциплинарных научных исследований, посвященных разработке действенных механизмов и инструментов для организации и повышения эффективности управления инновационными системами регионов в условиях цифровой трансформации экономики;
- во-вторых, необходимостью разработки аналитических и научно обоснованных методов, моделей и технологий управления инновационным развитием региональной экономики, учитывающих также скрытые закономерности в инновационных процессах;
- в-третьих, необходимостью разработки единой научной основы построения прогностических моделей инновационного развития региона, а также инструментальных средств для обоснования стратегических направлений социально-экономического развития и поддержки процессов принятия управленческих решений.

*Обзор литературы.* Проблеме использования нейронных сетей для анализа экономической деятельности хозяйствующих субъектов в условиях работы с «зашумленной информацией» для применения в таких областях, как оценка вероятности банкротства банка, операции на товарном рынке, контроль над инвестициями, оценка кредитоспособности и размещение займов, посвящены работы авторов А. Романовского, Н. А. Никифоровой, Е. В. Донцовой и др. [1, 2, 8, 15, 24].

В работе Е. Балатски и соавторов [18] разработана гибридная модель для прогнозирования инфляции, которая объединяет эконометрические и нейронные модели. В статье [20] рассматривается применимость ряда зарубежных и национальных моделей прогнозирования вероятности банкротства для российских предприятий.

### Методология исследования

Можно выделить два вида задач управления инновационным развитием экономики региона: оценка некоторых показателей по имеющемуся набору факторов (признаков) и прогноз поведения показателей во времени. Математически первый вид задач является задачей аппроксимации данных, а второй — задачей прогнозирования временных рядов.

Проблема оценки и построения прогностических моделей инновационного развития регионов и разра-

ботки систем поддержки принятия решений усложняется ввиду следующих обстоятельств:

- 1) разнородности факторов и параметров, определяющих инновационное развитие региона, оценка которых производится в условиях нелинейности и неопределенности (в условиях неоднозначной, асимметричной информации), что не позволяет формировать качественные и достоверные исходные данные;
- 2) отсутствия единой методики комплексной оценки инновационного развития региона, учитывающей специфические условия его развития, в частности, социокультурные региональные особенности;
- 3) отсутствия методики комплексного прогнозирования инновационного развития региона, позволяющей получать наиболее точные и достоверные результаты;
- 4) отсутствия аналитических и научно обоснованных методов управления инновационным развитием региональной экономики.

Одним из перспективных трендов в разработке моделей прогнозирования на данный момент является машинное обучение. Среди различных моделей машинного обучения наиболее гибкими являются искусственные нейронные сети (ИНС).

ИНС — это мягкие вычислительные методы, основанные на нейронной структуре человеческого мозга. С помощью ИНС можно моделировать сложные процессы, которые не представляется возможным моделировать с помощью традиционных количественных методов, используемых в финансах и экономике, по причине сложности перевода системы в точные функции.

ИНС состоят из трех основных уровней: ввод, скрытый слой и вывод. Более скрытые слои используются для моделирования более сложных зависимостей в системе данных. Первоначально нейронные связи внутри и между слоями устанавливаются со случайными весами, а затем модель корректирует веса в процессе обучения.

Этот метод моделирования полезен, когда основная структура модели неизвестна, так как модель имеет способность изучать самые разнообразные шаблоны из данных. ИНС показала свою эффективность для решения задач классификации групп и разработки краткосрочных прогнозов. Кроме того, ИНС прекрасно справляются с отсутствующими данными и корреляциями между входными переменными (мультиколлинеарность). Однако, стоит отметить, что процесс моделирования в ИНС является черным ящиком, и это может привести к неточности долгосрочных прогнозов.

Экономические данные для машинного обучения могут быть представлены в различных форматах и иметь пропуски. Поэтому необходима предварительная подготовка данных. Различные входные данные оказывают различное влияние на результат, поэтому необходим отбор данных, позволяющий сократить размерность входных данных и упростить обучение модели без заметного снижения качества предсказания.

Обучающие данные зачастую имеют пропуски. Исключение примеров с некомплектными данными

снижает объем и репрезентативность обучающей выборки. Поэтому используются различные методы с заполнением. При данном подходе пропущенные значения исходной выборки заполняются и полученные “полные” данные обрабатываются обычными методами.

Для формального отбора факторов можно применить три класса методов:

- методы фильтрации (filter methods);
- методы «обертки» (wrapper methods);
- встроенные методы (embedded methods).

Методы фильтрации основаны на статистических методах и позволяют оценить и ранжировать факторы по значимости, за которую принимается статистическая связь фактора с целевой переменной. Малозначимые факторы удаляются. Эти методы эффективны с точки зрения времени вычислений. Но методы фильтрации независимы от модели, поэтому не учитывают особенности модели. Например, нейросетевая модель является нелинейной, а корреляция линейна. Поэтому выбор факторов может быть не оптимальным.

Суть методов обертки состоит в том, что процедура отбора факторов «обертывается» процедурой, реализующей модель. Модель обучается на разных наборах факторов, которые выбирает процедура отбора. Выбирается набор факторов, обеспечивающий лучший показатель качества модели. Существуют три подхода в этом классе методов — методы включения (forward selection) и исключения (backwards selection) факторов и пошаговый подход (step wise). Первые стартуют с пустого подмножества, куда постепенно добавляются разные факторы. Во втором случае метод стартует с подмножества, равного исходному множеству факторов, и из него постепенно удаляются факторы. В пошаговом подходе на каждом шаге после добавления фактора проверяется возможность удаления фактора. Методы обертки учитывают особенности модели и взаимосвязь факторов. Но число подмножеств множества факторов выражается экспоненциальной зависимостью. Поэтому перебрать все подмножества обычно невозможно. Большинство подходов используют «жадные» алгоритмы, на каждом шаге которых выбирается лучшее по некоторому критерию подмножество, но никогда не пересматривается ранее сделанный выбор. Встроенные методы не разделяют отбор факторов и обучение модели, а производят отбор внутри процесса обучения модели. Эти методы основаны на регуляризации, то есть введении ограничений на параметры модели. Идея регуляризации состоит в том, чтобы построить алгоритм, минимизирующий не только ошибку модели, но и количество используемых переменных [21].

Нейронные сети являются универсальными аппроксиматорами функций. Для аппроксимации функций используются многослойные перцептроны и сети радиальных базисных функций.

Использование неинституциональной теории позволит в рамках разрабатываемой методологии включить в анализ региональные особенности экономических агентов, связанные со сложившимися неформальными институтами инновационной системы

(практиками реализации инновационных процессов, нормами, моделями поведения агентов и др.). Подробно разработанный методологический подход к исследованию региональной инновационной системы описан в ряде работ автора [3, 4].

В предыдущих исследованиях предложена также система интегральных показателей и индикаторов оценки уровня развития формального и неформального институционального контекста инновационной среды регионов в соответствии с разработанным неинституциональным системно-синергетическим методологическим подходом [3, 6]. Данный подход предполагает оценку следующих институтов инновационной среды (формальных и неформальных) и групп индикаторов для них:

1. Институт нормативно-правового обеспечения инновационной деятельности (П<sub>ИНПО</sub>). Группа индикаторов полноты нормативно-правового обеспечения инновационной деятельности в регионе. Группа индикаторов уровня развития правоприменительных механизмов в регионе. Группа индикаторов согласованности федерального и регионального законодательства в сфере инновационной деятельности.
2. Институт развития региона (П<sub>ИР</sub>). Группа индикаторов финансовой обеспеченности инновационной деятельности в регионе. Группа индикаторов наличия квалифицированных кадров для инновационного развития. Группа индикаторов наличия ресурсов для инновационного развития.
3. Институт стратегического планирования инновационной деятельности (П<sub>ИСП</sub>). Группа индикаторов наличия формализованных элементов стратегического инновационного планирования.
4. Институт профессионального образования и науки (П<sub>ИПОИН</sub>). Группа индикаторов результативности системы высшего профессионального образования в регионе. Группа индикаторов качества высшего образования в регионе. Группа индикаторов финансовой обеспеченности научных исследований и разработок в регионе.
5. Институт интегрированных коммуникаций (И<sub>ИК</sub>). Группа индикаторов коммуникационной активности инновационных предприятий.
6. Институт стандартизации инновационной деятельности (П<sub>ИС</sub>). Группа индикаторов, характеризующих отраслевые стандарты, регулирующие инновационную деятельность.
7. Институт мониторинга изменений на целевых рынках и в технологических областях (П<sub>ИМИЗМ</sub>). Группа индикаторов, характеризующих работу систем поиска и мониторинга инновационной активности в регионе.
8. Институт информационной поддержки в инновационной сфере (И<sub>ИНФП</sub>). Группа индикаторов, характеризующих степень развития информационных технологий и телекоммуникационной базы в регионе.
9. Институт конкуренции (П<sub>ИК</sub>). Группа индикаторов, характеризующих конкурентное взаимодействие и взаимосвязь хозяйствующих субъектов в регионе.

10. Институт кооперации с научно-исследовательскими организациями (П<sub>ИОКК</sub>). Группа индикаторов, характеризующих кооперативное взаимодействие хозяйствующих субъектов с научно-исследовательскими организациями в регионе.
11. Институт кооперации и интеграции на рынке инноваций (П<sub>ИКИИ</sub>). Группа индикаторов, характеризующих кооперативное взаимодействие и интеграцию хозяйствующих субъектов в регионе.
12. Институт защиты интеллектуальной собственности (П<sub>ИИнтС</sub>). Группа индикаторов, характеризующих степень защиты интеллектуальной собственности предприятий в регионе.
13. Институт кооперации внутри предприятия и развития инновационного потенциала сотрудников (П<sub>ИКИИПП</sub>). Группа индикаторов, характеризующих кооперативное взаимодействие сотрудников предприятия и уровень развития инновационного потенциала.
14. Институт финансирования инновационной деятельности (П<sub>ИФ</sub>). Группа индикаторов, характеризующих степень грантовой поддержки и государственного субсидирования инновационных предприятий в регионе. Группа индикаторов, характеризующих наличие прямого финансирования исследований и разработок инновационных предприятий.
15. Институт кредитования инновационной деятельности (П<sub>ИКред</sub>). Группа индикаторов, характеризующих эффективность действующих кредитных программ, а также доступность банковских кредитов на реализацию инновационных проектов в регионе.
16. Институт теневых экономических отношений (П<sub>ТЭО</sub>). Группа индикаторов, характеризующих наличие «серых» схем работы предприятий в регионе. Группа индикаторов, характеризующих уровень коррупции в регионе.
17. Институт инновационного посредничества (П<sub>ИПоср</sub>). Группа индикаторов, характеризующих доступность и эффективность функционирования объектов инновационного посредничества (бизнес-инкубаторов, бизнес-ангелов и т. п.) в регионе [3].

Значимость отдельных показателей должна определяться методом корреляционного анализа, что позволит избежать субъективности оценок и обеспечить достоверность рассчитываемых в дальнейшем интегральных показателей. Для преодоления проблемы мультиколлинеарности факторов и снижения размерности показатели с незначительной значимостью исключаются [3]. При этом важно было выделить и исследовать те экономические параметры, с помощью сознательного изменения которых создается возможность менять ход и направление инновационных процессов (управляющие параметры), которые в свою очередь связаны, по нашему мнению, преимущественно, с институциональной составляющей инновационной системы региона (рис. 1).

Проведенные ранее исследования показали наличие зависимости между рейтингом инновационной активности региона, а также отдельными показателя-




Рис. 1. Схема модели нейросетевого управления

ми, характеризующими его инновационное развитие, периодически рассчитываемыми Росстатом, и объемом создаваемого ВРП [3]. Следовательно, посредством оценки и прогнозирования развития институциональной составляющей инновационной системы региона появляется возможность моделировать региональный экономический рост.

### Результаты

В рамках настоящего исследования целесообразно использовать самоорганизующиеся (эволюционирующие), а не полносвязные нейронные сети. Использование принципов самоорганизации позволяет синтезировать многослойные нейронные сети на неполной, непредставительной обучающей выборке.

Важно отметить, что для построения нейронной сети, позволяющей допускать минимальное число ошибок на обучающей выборке, отсутствует необходимость в предварительной оценке значимости переменных (параметров порядка), а также в установлении синаптических связей.

Алгоритм функционирования обучающихся сетей представляет собой один из вариантов кластеризации многомерных векторов. Важным отличием данного алгоритма является то, что в нем все нейроны упорядочены в некоторую структуру.

Основными этапами проведения нейросетевого анализа являются следующие:

- предпроцессорная обработка данных;
- сбор данных;
- обработка данных;
- анализ нейронных сетей;
- анализ результатов прогнозирования уровня институционального развития инновационной системы региона.

#### 1. Сбор данных.

База данных нашего исследования основана на результатах статистического исследования инновационной среды субъектов РФ (на примере 20 регионов). В результате были рассчитаны частные интегральные показатели оценки уровня развития формального институционального контекста региональных инновационных систем. Согласно методологии исследования, данные показатели по сути являются параметрами порядка, определяющими поведение компонент системы.

В частные интегральные показатели оценки уровня развития формального институционального контекста региональной инновационной системы (РИС) входят девять показателей. Кроме того, с целью учета ограничивающих факторов в группу был добавлен показатель

социокультурного фона (П\_СФ), отражающий степень выраженности и риск, связанный с влиянием социокультурных факторов на институциональное развитие региона, принимающий следующие значения [0,25; 0,5; 0,75; 1]. При этом, 0,25 означает низкую готовность к институциональным изменениям (высокий уровень риска проведения институциональных изменений в РИС); 1 — высокую готовность к институциональным изменениям в инновационной системе региона (низкий уровень риска проведения институциональных изменений в РИС).

2. Обработка данных.

Для нейронной сети из полученных данных были сформированы обучающая, тестовая и контрольная выборки. Так как вся выборка по интегральным показателям оценки уровня развития формального институционального контекста состоит из исследований по 70% — для тестового множества и 30 % — для контрольного множества.

3. Анализ нейронных сетей.

В ходе экспериментов проанализированы и построены нейронные сети различной конфигурации. Предлагается использовать многослойную сеть, т. е. сеть прямого распространения для прогнозирования ключевых характеристик желаемого образа инновационного развития регионов (рис. 2). Многослойный перцептрон в общем представлении состоит из следующих элементов: множества входных узлов, которые образуют входной слой, одного или нескольких скрытых слоев вычислительных нейронов, одного выходного слоя нейронов.

Цель обучения многослойной сети состоит в настройке весов и смещений сети, чтобы при заданном входном векторе  $x$  получить на выходе значения сигналов  $y_i$ , которые с требуемой точностью будут совпадать с ожидаемыми значениями  $d_i$  для  $i=1, 2, \dots, p$ . С использованием собранных данных веса пороговые значения автоматически корректируются с целью минимизации ошибки. Вычисление выхода слоя заключается в умножении входного вектора на вектор весов с последующим умножением результирующего вектора на второй вектор весов. В результате, выходной сигнал можно описать функцией:




Рис. 2. Двухслойная нейронная сеть: индекс (1) — веса нейронов скрытого слоя, индекс (2) — веса нейронов выходного слоя,  $g_j$  ( $j=1, 2, \dots, L$ ) — выходные сигналы нейронов скрытого слоя,  $y_j$  ( $j=1, 2, \dots, M$ ) — выходные сигналы выходного слоя

$$y_k = f\left(\sum_{i=0}^K w_{2ki} u_i\right) = f\left(\sum_{i=0}^K w_{2ki} f\left(\sum_{j=0}^N w_{1ij} x_j\right)\right).$$

где  $w_{ij}$  — веса нейронов скрытых слоев;  $u_i$  — выходной сигнал  $i$ -го нейрона скрытого слоя;  $x$  — входной вектор;  $y$  — выходное значение.

Исследования проводились с использованием пакета Neural Network Toolbox системы Matlab.

Нейронная сеть реализует прогнозирование уровня инновационного развития региона. Входами сети являются девять интегральных показателей оценки уровня развития формального институционального контекста (П\_ИНПО, П\_ИР, П\_ИПОиН, П\_ИФ, П\_ИИИФП, П\_ИК, П\_ИИИнтС, П\_ИПоср, П\_СФ). Единственным выходом сети является признак институционального развития инновационной системы региона. Данный признак изменяется в пределах от 0 до 1; 0 — соответствует низкому уровню институционального развития инновационной системы региона, 1 соответствует высокому уровню развития.

Построение сети идет в два этапа: разработка математической модели и обучение сети. Исследования проводились с использованием многослойной нейронной сети прямого распространения. В качестве функции активации использовалась логарифмическая сигмоидная функция активации:

$$f(x) = \frac{1}{1 + \exp(-x)}, \quad (1)$$

где  $x$  — входной вектор.

В качестве алгоритма обучения использовался метод шкалированных связанных градиентов. Данная функция обучения сети модифицирует веса и смещения в соответствии с методом шкалированных связанных градиентов. Данный метод может обучать любую сеть до тех пор, пока ее вес, вход сети и функция активации имеют производные функции. Обратное распределение используется для вычисления производных производительности по весу и переменным смещения  $x$ .

Исследования проводились с использованием многослойной нейронной сети прямого распространения. В качестве функция активации использовалась логарифмическая сигмоидная функция активации (1). В качестве алгоритма обучения использовался метод шкалированных связанных градиентов. Структура сети представлена на рис. 3.

Испытания проводились на трехслойной сети (входной, скрытый и выходной слой). Количество нейронов входного и выходного слоев определялось количеством входных и выходных переменных. Подбиралось количество нейронов в скрытом слое. Экспериментально установлено, что по величине ошибки классификации лучшей является нейронная сеть с 17 нейронами в скрытом слое.

Экспериментально установлено, что по величине ошибки классификации лучшей является нейронная сеть с 10 нейронами в скрытом слое.

В результате обучения сети была построена матрица неточностей (рис. 4).

Данная матрица показывает процент правильно и неправильно распознанных классов по областям.

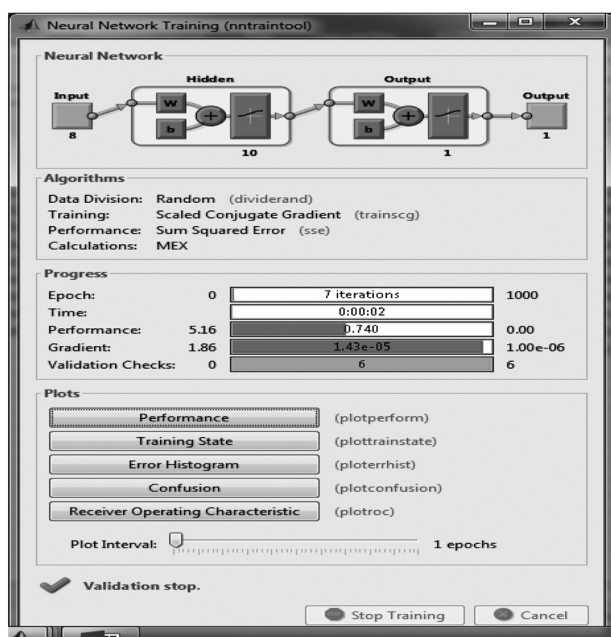


Рис. 3. Структура нейронной сети

Также для оценки качества классификации был использован ROC-анализ (рис. 5). «ROC-кривая, также известная как кривая ошибок, отображает соотношение между долей верных положительных классификаций от общего числа положительных классификаций (true positive rate) с долей ошибочных положительных классификаций от общего числа отрицательных классификаций (false positive rate) при варьировании порога решающего правила. Показатель AUC (площадь под ROC-кривой) дает количественную интерпретацию ROC-кривой. Считается, что чем выше показатель AUC, тем качественнее классификатор».

На данной сети с конфигурацией 8-10-1 показатель AUC составил 0,88, это говорит о достаточно точном методе классификации. Теоретически величина AUC изменяется от 0 до 1,0, но, поскольку модель всегда характеризуется кривой, расположенной выше положительной диагонали, то обычно говорят об изменениях от 0,5 («бесполезный» классификатор) до 1,0 («идеальная» модель). Эта оценка может быть получена с использованием численного метода трапеций:

$$AUC = \int f(x) dx = \sum_i \left[ \frac{X_{i+1} + X_i}{2} \right] (Y_{i+1} - Y_i),$$

где  $X$  — специфичность,  $Y$  — чувствительность. Причем:

$$Y = a / (a + c); X = d / (d + b),$$

где  $a$  — истинно положительный результат;  $b$  — ложноположительный результат;  $c$  — ложноотрицательный результат;  $d$  — истинно отрицательный результат.

Примечательно, что при подаче на вход сети только параметров порядка РИС, выявленных на предыдущих этапах настоящего исследования, ошибка сети не изменилась, это свидетельствует, во-первых, о качестве построенной сети; во-вторых, о правильном выявлении предикторов в построенных экономико-математических моделях, описывающих влияние

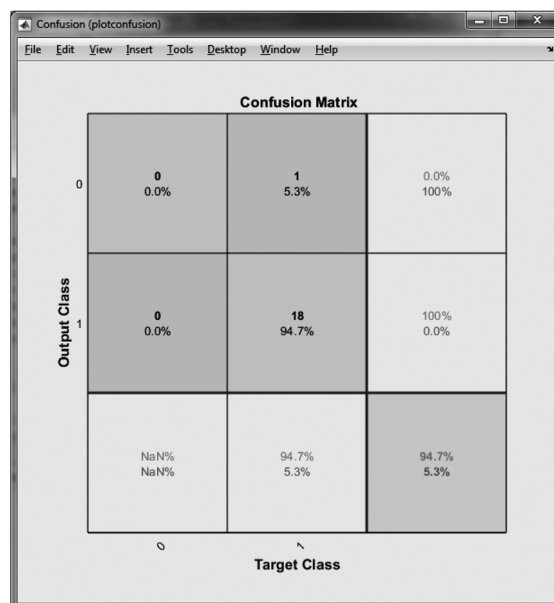


Рис. 4. Матрица неточностей

факторов на уровень институционального потенциала региона с точки зрения его инновационной способности и институциональной восприимчивости.

Аналогичные процедуры моделирования на основе нейросети были проделаны на базе показателей оценки неформального институционального контекста региона, однако ошибка классификации на основе построенной модели оказалась неприемлемой.

Кроме того, для определения уровня институционального развития инновационной системы региона с использованием разработанного нейросетевого подхода не придется рассчитывать интегральные показатели за несколько лет, как это было сделано для проведения необходимых экспериментов в настоящем исследовании, так как построенная искусственная нейронная сеть после машинного обучения способна идентифицировать уровень институционального развития РИС на данных, рассчитанных за один год.




Рис. 5. ROC-кривая



Рис. 6. Алгоритм управления и прогнозирования развития региональной инновационной системы

Таким образом, алгоритм методологии управления РИС на основе неинституционального системно-синергетического подхода будет выглядеть следующим образом (рис. 6).

Подводя итог проделанной работе можно сделать следующие выводы:

1. Реализована общая концепция нейронной сети для решения прогностических задач в региональной инновационной системе.
2. Установлено, что ошибка прогноза после обучения

ИНС является приемлемой и составляет 10-15% в зависимости от конкретной предметной области при этом скорость обработки информации значительна.

3. Представленные в работе прогностические модели являются основой для разработки систем управления региональными инновационными системами.

### Направления будущих исследований

Использование технологий извлечения и интеллектуального анализа больших данных о результатах инновационной деятельности субъектов позволит многократно повысить качество и достоверность исходной информации, необходимой для анализа инновационных процессов в региональных экономических системах. Далее на основе полученного массива данных необходимо решить задачу прогнозирования развития инновационной деятельности в конкретном регионе и эргономичной визуализации комплекса его параметров в целях информационной поддержки управленческих решений. Моделирование инновационных процессов на основе нейросетевого подхода с использованием технологии машинного обучения обеспечит возможность обобщать накопленные знания, производить их обучение, использовать для прогнозирования будущего состояния системы. В будущих исследованиях планируется применение нейросетевого моделирования для решения задач классификации событий в городской экосистеме по степени их критичности с точки зрения влияния на уровень устойчивого развития и качества жизни населения города.

### Благодарность

Исследование выполнено в рамках гранта РФФИ № 18-010-00204-а. Результаты исследований, представленные в разделе «Результаты», получены за счет средств Российского научного фонда (проект № 20-71-10087).

### Список использованных источников

1. Ю. А. Алексеева. Оценка финансового состояния и прогнозирование банкротства предприятия. Автореферат дисс. М., 2011.
2. Т. К. Богданова, А. В. Баклакова. Инструментальные средства прогнозирования вероятности банкротства авиапредприятий//Бизнес-информатика. 2008. № 1. С. 45-61.
3. Л. А. Гамидуллаева. Теоретико-методологические основы управления и прогнозирования развития инновационной системы региона: дис. ...д-ра экон. наук. Санкт-Петербургский государственный университет. СПб.: СПбГУ, 2019.
4. Л. А. Гамидуллаева. Возможности неинституционального системно-синергетического подхода к исследованию инновационных систем//Журнал экономической теории. 2015. № 4. С. 142-154.
5. Л. А. Гамидуллаева. От шумпетерианской теории созидательного разрушения к синергетической парадигме инноваций//Журнал экономической теории. 2019. Т. 16. № 3. С. 498-512.
6. Л. А. Гамидуллаева. Институты в развитии инновационных систем// Вопросы регулирования экономики (Journal of Economic Regulation). 2016. Т. 7. № 1. С. 93-103.
7. Н. А. Никифорова, Е. В. Донцов. Применение нейросетевого моделирования для прогнозирования финансового состояния предприятия//Управленческий учет. 2011. № 4. С. 36-46.
8. Е. М. Коростышевская, В. А. Плотноков, А. В. Пролубников, М. В. Рукинов. Социальная компонента государственной региональной политики и ее роль в обеспечении устойчивого развития и экономической безопасности//Известия Санкт-Петербургского государственного экономического университета. 2018. № 6 (114). С. 120-126.
9. С. Оссовский. Нейронные сети для обработки информации. М.: Горячая линия Телеком, 2016. 448 с.
10. П. Н. Панфилов. Введение в нейронные сети//Современный трейдинг. 2001. № 2. С. 12-17.
11. Плас Дж. Вандер. Python для сложных задач: наука о данных и машинное обучение. СПб.: Питер, 2018. 576 с.
12. Г. З. Рахимкулова. Аналитические и нейрокомпьютерные модели оценки кредитоспособности предприятия//Аудит и финансовый анализ. 2007. № 3. С. 196-198.
13. С. Рашка. Python и машинное обучение. М.: ДМК Пресс, 2017. 418 с.
14. А. В. Романовский. О применении искусственных нейронных сетей для прогнозирования финансовых показателей предприятия//Аудит и финансовый анализ. 2013. № 2. С. 363-370.
15. И. С. Светульников. Краткосрочное прогнозирование социально-экономических процессов с использованием модели с коррекцией//Бизнес Информ. 2011. Т. 1. № 5. С. 109-112.

16. П. Флах. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. М.: ДМК Пресс, 2015. 400 с.
17. E. V. Balatskii, N. A. Ekimova, M. A. Yurevich. Short-Term Inflation Projection Based on Marker Models//Stud. Russ. Econ. Dev. 30, 498-506, 2019.
18. J. Carpenter, M. Kenward. Multiple Imputation and its Application. Wiley, 2013. 364 p.
19. E. A. Fedorova, E. V. Gilenko, S. E. Dovzhenko. Models for bankruptcy forecasting: Case study of Russian enterprises//Stud. Russ. Econ. Dev. 24, 159-164, 2013.
20. V. I. Gorbachenko, O. Yu. Kuznetsova, D. S. Silnov. Investigation of Neural and Fuzzy Neural Networks for Diagnosis of Endogenous Intoxication Syndrome in Patients with Chronic Renal Failure//International Journal of Applied Engineering Research, 2016, Vol. 11. № 7. P. 5156-5162.
21. J. C. Neves, A. Vieira. Improving bankruptcy prediction with hidden layer learning vector quantization//European Accounting Review. 2006. Vol. 15. № 2. P. 253-271.
22. K. Schirmer, M. Kuehn. Fact Extraction from Financial News. In Proceedings of the Second International Conference on Artificial Intelligence Applications on Wall Street. New York, NY, April, 1993. Gaithersburg, MD: Software Engineering Press.
23. M. Tkáč, R. Vermer. Artificial neural networks in business: Two decades of research//Applied Soft Computing. Vol. 38. 2016. P. 788-804.

## References

1. Yu. A. Alekseeva. Ocenka finansovogo sostoyaniya i prognozirovanie bankrotstva predpriyatiya. Avtoreferat diss. M., 2011
2. T. K. Bogdanova, A. V. Baklakova., Instrumental'nye sredstva prognozirovaniya veroyatnosti bankrotstva aviapredpriyatij//Biznes-informatika. 2008. № 1. S. 45-61.
3. L. A. Gamidullaeva. Teoretiko-metodologicheskie osnovy upravleniya i prognozirovaniya razvitiya innovacionnoj sistemy regiona: dis. ... d-ra ekon. nauk. SPb.: SPbGU, 2019.
4. L. A. Gamidullaeva. Vozmozhnosti neoinstitucional'nogo sistemno-sinergeticheskogo podhoda k issledovaniyu innovacionnyh sistem//Zhurnal ekonomicheskoy teorii. 2015. № 4. S. 142-154.
5. L. A. Gamidullaeva. Ot shumpeterianskoj teorii sozidatel'nogo razrusheniya k sinergeticheskoy paradigme innovacij//Zhurnal ekonomicheskoy teorii. 2019. T. 16. № 3. S. 498-512.
6. L. A. Gamidullaeva. Instituty v razvitiy innovacionnyh sistem//Journal of Economic Regulation (Voprosy regulirovaniya ekonomiki). 2016. T. 7. № 1. S. 93-103.
7. N. A. Nikiforova, E. V. Doncov. Primenenie nejrosetevogo modelirovaniya dlya prognozirovaniya finansovogo sostoyaniya predpriyatiya//Upravlencheskij uchët. 2011. № 4. S. 36-46.
8. E. M. Korostyshevskaya, V. A. Plotnikov, A. V. Prolubnikov, M. V. Rukinov. Social'naya komponenta gosudarstvennoj regional'noj politiki i ee rol' v obespechenii ustojchivogo razvitiya i ekonomicheskoy bezopasnosti//Izvestiya Sankt-Peterburgskogo gosudarstvennogo ekonomicheskogo universiteta. 2018. № 6 (114). S. 120-126.
9. S. Osovskij. Nejronnye seti dlya obrabotki informacii. M.: Goryachaya liniya Telekom, 2016. 448 s.
10. P. N. Panfilov. Vvedenie v nejronnye seti//Sovremennyy trejding. 2001. № 2. S. 12-17.
11. Plas Dzh. Vander. Python dlya slozhnyh zadach: nauka o dannyh i mashinnoe obuchenie. SPb.: Piter, 2018. 576 s.
12. G. Z. Rahimkulova. Analiticheskie i nejrokompyuternye modeli ocenki kreditosposobnosti predpriyatiya//Audit i finansovyj analiz. 2007. № 3. S. 196-198.
13. S. Rashka. Python i mashinnoe obuchenie. M.: ДМК Пресс, 2017. 418 s.
14. A. V. Romanovskij. O primenenii iskusstvennyh nejronnyh setej dlya prognozirovaniya finansovyh pokazatelej predpriyatiya//Audit i finansovyj analiz. 2013. № 2. S. 363-370.
15. I. S. Svetun'kov. Kratkosrochnoe prognozirovanie social'no-ekonomicheskikh processov s ispol'zovaniem modeli s korekciej//Biznes Inform. 2011. T. 1. № 5. S. 109-112.
16. P. Flah. Mашинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. М.: ДМК Пресс, 2015. 400 с.
17. E. V. Balatskii, N. A. Ekimova, M. A. Yurevich. Short-Term Inflation Projection Based on Marker Models//Stud. Russ. Econ. Dev. 30, 498-506, 2019.
18. J. Carpenter, M. Kenward. Multiple Imputation and its Application. Wiley, 2013. 364 p.
19. E. A. Fedorova, E. V. Gilenko, S. E. Dovzhenko. Models for bankruptcy forecasting: Case study of Russian enterprises//Stud. Russ. Econ. Dev. 24, 159-164, 2013.
20. V. I. Gorbachenko, O. Yu. Kuznetsova, D. S. Silnov. Investigation of Neural and Fuzzy Neural Networks for Diagnosis of Endogenous Intoxication Syndrome in Patients with Chronic Renal Failure//International Journal of Applied Engineering Research, 2016, Vol. 11. № 7. P. 5156-5162.
21. J. C. Neves, A. Vieira. Improving bankruptcy prediction with hidden layer learning vector quantization//European Accounting Review. 2006. Vol. 15. № 2. P. 253-271.
22. K. Schirmer, M. Kuehn. Fact Extraction from Financial News. In Proceedings of the Second International Conference on Artificial Intelligence Applications on Wall Street. New York, NY, April, 1993. Gaithersburg, MD: Software Engineering Press.
23. M. Tkáč, R. Vermer. Artificial neural networks in business: Two decades of research//Applied Soft Computing. Vol. 38. 2016. P. 788-804.