

**НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ МОТИВАЦИИ
ТОП-МЕНЕДЖМЕНТА ГОСУДАРСТВЕННЫХ СТРУКТУР
РЕГИОНОВ КАК ЗАДАЧА КЛАССИФИКАЦИИ*****Сергей Николаевич ЯШИН^а; Егор Викторович КОШЕЛЕВ^б,
Александр Вячеславович КУПЦОВ^с**

^а доктор экономических наук, профессор, заведующий кафедрой менеджмента и государственного управления, Нижегородский государственный университет им. Н.И. Лобачевского, Нижний Новгород, Российская Федерация
jashinsn@yandex.ru
<https://orcid.org/0000-0002-7182-2808>
SPIN-код: 4191-7293

^б кандидат экономических наук, доцент кафедры менеджмента и государственного управления, Нижегородский государственный университет им. Н.И. Лобачевского, Нижний Новгород, Российская Федерация
ekoshelev@yandex.ru
<https://orcid.org/0000-0001-5290-7913>
SPIN-код: 8429-5702

^с кандидат экономических наук, доцент кафедры менеджмента и государственного управления, Нижегородский государственный университет им. Н.И. Лобачевского, Нижний Новгород, Российская Федерация
kav191982@yandex.ru
ORCID: отсутствует
SPIN-код: 1755-5529

* Ответственный автор

История статьи:

Рег. № 252/2023
Получена 01.06.2023
Получена в доработанном виде 19.06.2023
Одобрена 03.07.2023
Доступна онлайн 30.10.2023

Специальность: 5.2.3

УДК 332.142.2

JEL: C38, C45, H83, O21, R58

Ключевые слова:

мотивация топ-менеджмента, нейронные сети, задача классификации

Аннотация

Предмет. Моделирование мотивации топ-менеджеров государственных структур регионов, соответствие интересов населения и государства.

Цели. Создание нейросетевой модели мотивации топ-менеджмента государственных структур регионов для задачи классификации.

Методология. Использованы нейронные сети, методы моделирования и классификации.

Результаты. Смоделированы критерии нематериальной и материальной мотивации топ-менеджмента государственных структур регионов, а также критерии стратегического потенциала региона. Предполагалось, что развитие потенциала в будущем может повлиять на оба вида мотивации топ-менеджеров. Целевой функцией является коэффициент естественного прироста населения. Решена задача двоичной классификации в обучаемой нейронной сети. Суммарная ошибка на верификации по функциям нематериальной, материальной мотивации и стратегического потенциала составила 12%. Это говорит о том, что нейронные сети позволяют достичь гораздо большей точности прогноза.

Выводы. Полученные результаты могут быть полезны государственным структурам регионов для разработки конструктивной системы материальной и нематериальной мотивации топ-менеджеров.

* Исследование выполнено в рамках реализации программы стратегического академического лидерства «Приоритет 2030», проект Н-426-99_2022-2023 «Социально-экономические модели и технологии развития креативного человеческого капитала в инновационном обществе».

Для цитирования: Яшин С.Н., Кошелев Е.В., Купцов А.В. Нейросетевое моделирование мотивации топ-менеджмента государственных структур регионов как задача классификации // *Финансы и кредит*. — 2023. — Т. 29, № 10. — С. 2253 — 2273.
<https://doi.org/10.24891/fc.29.10.2253>

Вопросы конструктивной мотивации топ-менеджмента государственных структур всегда важны для планирования сбалансированного развития региональных экономических систем. Несмотря на значительное число научных работ в этой сфере, до сих пор нет универсальных моделей мотивации. Таким образом, вопрос остается открытым.

С возникновением науки о данных (Data Science) появились новые современные методы моделирования сложных процессов и систем. Это оправдано в случае наличия больших массивов данных (Big Data), обработка которых требует серьезных вычислительных алгоритмов. Здесь мы говорим в числе прочего о нейросетевом моделировании, которое применимо и для планирования конструктивной мотивации топ-менеджмента в государственном секторе экономики.

Сама проблема мотивации топ-менеджмента исследуется разными учеными уже давно, что позволило выработать основополагающие принципы этого процесса.

Руководитель всегда имеет возможность влиять на других, и существует три типа навыков управленческого руководства, а именно: технические навыки, навыки межличностного общения и навыки принятия решений (А. Мунна [1]).

Исследование мотивации на государственной службе распространилось параллельно с вопросом о том, как улучшить производительность персонала государственной службы. Результаты исследования Р. Кристенсена, Л. Палберга и Дж. Перри [2] подтверждают ряд уроков, среди них использование мотивации государственной службы в качестве инструмента отбора, содействие мотивации в государственной службе посредством сотрудничества на рабочем месте, передача значимости работы и формирование лидерства на основе ценностей государственной службы.

В статье К. Серан, Е. Ачи и Е. Николас [3] рассматривается важность факторов мотивации занятости в государственном секторе Ливана. Проводится качественное собеседование с работодателями и работниками государственного сектора Ливана, чтобы получить их ответы на вопросы о том, что они считают наилучшими факторами, которые мотивируют их на работе. В свете этого в статье определяются наиболее ранжированные факторы из десяти мотивационных факторов, которые, как считается, влияют на мотивацию сотрудников в организациях государственного сектора. Анализ эмпирических результатов (с использованием программного обеспечения NVivo) показал, что вознаграждение и условия труда являются

ключевыми для повышения мотивации сотрудников. Следует также рассмотреть вопросы поощрения, автономии, участия в принятии решений, трудовых социальных отношений и коммуникации. И наконец, предлагаются руководящие принципы и рекомендации по внедрению результатов исследований в отношении вознаграждения и предложений по оценке условий труда.

В статье А. Рица, В. Ванденабель и Д. Вогеля [4] рассматривается роль мотивации государственных служащих и ее связь с индивидуальными показателями работы. Более конкретно эти отношения изучаются путем сосредоточения внимания на мотивации в государственной службе (Public Service Motivation, PSM), потоке исследований, разработанных в течение последних трех десятилетий, подчеркивается ориентация на обслуживание личности государственного служащего. Обсуждается, как взаимосвязь между PSM и индивидуальной производительностью зависит от соответствующих институтов, и представляется обзор существующих эмпирических данных, касающихся этой взаимосвязи.

Поскольку в настоящей работе для моделирования мотивации топ-менеджмента государственных структур регионов применяется построение и обучение нейронных сетей, остановимся подробнее на том типе задачи, которая в данном случае решается.

Одними из базовых проблем нейросетевого моделирования являются задача классификации и задача регрессии. Прежде чем обсуждать проблему классификации, важно понять, что существует несколько типов классификации. В частности, это:

- двоичная классификация — когда число классов равно двум, например, классификация электронной почты как спама или нет;
- мультиклассовая классификация — когда существует более двух различных классов, таких как в наборе данных цветов ириса, где классы являются различными типами цветов;
- классификация с несколькими метками — если входные данные имеют несколько классов, например, классификация изображений с несколькими объектами в них;
- если входные данные являются изображениями, классификация может быть пиксельной (или сегментацией изображения), когда каждый пиксель имеет свой собственный класс.

Знание типа классификации помогает выбрать подходящий тип моделей и соответствующие обучающие параметры, такие как функция потерь. Например, для двоичной классификации функция `binary_crossentropy` часто используется в качестве функции потерь, тогда как `categorical_crossentropy` используется для классификации нескольких классов.

Решение задач классификации с помощью нейронных сетей имеет уже давнюю традицию, что позволило получить новые полезные результаты в разных областях знания.

Так, мониторинг процессов считается одной из наиболее важных проблем в проектировании технологических систем, которая может быть полезна в методах глубокого обучения. В статье С. Хео и Дж. Ли [5] глубокие нейронные сети применяются к проблеме обнаружения и классификации неисправностей для иллюстрации их работоспособности. Во-первых, проблемы обнаружения и классификации неисправностей формулируются как проблемы классификации на основе нейронной сети. Затем нейронные сети обучают выполнять обнаружение неисправностей, и авторы исследуют влияние двух гиперпараметров (количество скрытых слоев и количество нейронов в последнем скрытом слое) и увеличения данных на производительность нейронных сетей. Проблема классификации отказов также решается с помощью нейронных сетей с увеличением объема данных. Наконец, результаты, полученные из глубоких нейронных сетей, сравниваются с другими методами с управляемыми данными, чтобы проиллюстрировать преимущества глубоких нейронных сетей.

В работе А. Сысоева и В. Майорова [6] оценивается применимость моделей пар сущностей и нейросетевых архитектур для извлечения и классификации отношений в научных работах на SemEval-2018. Проводятся эксперименты с представлением пар сущностей через маркеры предложений и через кратчайший путь в дереве зависимостей, сравниваются подходы, основанные на сверточных и повторяющихся нейронных сетях.

Модели нейронных сетей для многих задач в последние годы становятся все более сложными, что затрудняет их обучение и применение. В ряде недавних документов была поставлена под сомнение необходимость таких архитектур и было установлено, что хорошо выполненные более простые модели являются достаточно эффективными. А. Адхикари и др. [7] показали, что это также относится к классификации документов. В крупномасштабном исследовании воспроизводимости нескольких недавних нейронных моделей обнаружено, что простая архитектура с соответствующей регуляризацией дает точность, которые либо конкурентоспособны, либо превосходят уровень техники по четырем стандартным наборам эталонных данных.

Сверточная нейронная сеть (Convolutional Neural Network, CNN) как класс искусственных нейронных сетей стала доминирующей в различных областях, включая анализ и обработку текста. Она предназначена для автоматического и адаптивного изучения пространственных иерархий объектов с обратным рассеянием с использованием нескольких строительных блоков, таких как сверточные слои, слои группировки и полностью соединенные слои. Статья М. Эч-Чоух, Х. Омара и М. Лазара [8] направлена на представление подхода,

основанного на CNN, для классификации научных статей по их доменам (семь различных доменов) из рефератов. Процесс основан на нескольких особенностях, автоматически извлеченных из резюме. Предложенный подход показал замечательные результаты для автоматической классификации текста по сравнению с другими обычными алгоритмами автоматического обучения.

Работа А. Романова, К. Ломотина и Е. Козловой [9] посвящена исследованию применимости современных методов машинного обучения к задаче автоматической классификации научных статей и рефератов. Для этого проводилось рассмотрение таких моделей машинного обучения, как искусственные нейронные сети, случайный лес, логистическая регрессия, метод опорных векторов с учетом особенностей научных текстов, в том числе большого количества терминов, специфических для различных категорий. Отдельно рассматриваются этапы сбора данных и извлечения текстовых признаков. Результаты исследований используются при разработке системы поддержки принятия решений по отнесению научных текстов к коду отдела или реферативного журнала Всероссийского института научно-технической информации РАН.

В статье А. Венкатарамана и П. Агарваля [10] представлен подход глубокого обучения для выявления и классификации болезней растений путем исследования их листьев. Классификация выполняется в несколько этапов, чтобы исключить возможности заражения растений на каждом этапе, что обеспечивает лучшую точность прогнозов.

Большинство существующих систем распознавания изображений базируются на физических параметрах, в то время как методологии обработки изображений основаны на извлечении признаков цвета, формы и очертаний. Таким образом, Transfer Learning является эффективным подходом к решению проблемы классификации с небольшим объемом данных. Существует много алгоритмов глубокого обучения, но наиболее проверенным является AlexNet. Это хорошо известная нейронная сеть свертки (AlexNet CNN) для распознавания изображений с помощью глубокого обучения (С. Корде и др. [11]).

В статье Р. Аверса и др. [12] сообщается о недавней работе, направленной на улучшение и адаптацию алгоритмов машинного обучения для автоматической классификации нано научных изображений, полученных сканирующим электронным микроскопом. Для этого используются контролируемые и неконтролируемые подходы к обучению. Сначала исследуется контролируемое обучение по набору данных 10 категорий изображений и сравнивается производительность различных моделей с точки зрения точности обучения. Затем уменьшается размерность элементов с помощью автокодеров для выполнения неконтролируемого обучения на подмножестве изображений в выбранном диапазоне. Наконец, сравниваются различные методы кластеризации, чтобы раскрыть внутренние структуры в изображениях.

Спутниковые снимки имеют большое значение для многих областей применения, включая реагирование на стихийные бедствия, правоохранительную деятельность, мониторинг окружающей среды и т.д. Эти приложения требуют ручной идентификации объектов в изображении. Поскольку географический район, который должен быть охвачен, очень велик, а аналитики, доступные для проведения поисков, немногочисленны, требуется автоматизация. Однако традиционные алгоритмы обнаружения и классификации объектов слишком неточны и ненадежны для решения проблемы. Глубокое обучение является частью более широкого семейства методов машинного обучения, которые показали перспективность автоматизации таких задач. Оно достигло успеха в понимании изображения с помощью сверточных нейронных сетей. Р. Раджендран и Л. Самуэль [13] рассматривают проблему распознавания объектов в спутниковых снимках. Система состоит из ансамбля сверточных нейронных сетей и дополнительных нейронных сетей, интегрирующих спутниковые метаданные с особенностями изображения.

Основная цель статьи Р. Нитья [14] состоит в обучении классификатора изображений с использованием сверточных нейронных сетей с тензортекущей архитектурой. Предлагаемый документ посвящен систематическим подходам к классификации выборочного набора изображений с использованием сверточных нейронных сетей. Таким образом, модель CNN с функцией активации классифицирует набор данных на две категории, точно как человек. Таким образом, в документе подчеркивается важность увеличения изображений путем сравнения их точности.

Классификация последовательностей играет важную роль в исследованиях метагеномики. Д. Ву, М. Грюнвальд и Г. Веркли [15] оценивают подход глубокой нейронной сети для классификации последовательностей грибов, поскольку он стал успешной парадигмой для классификации и кластеризации больших данных. Два классификатора на основе глубокого обучения, сверточная нейронная сеть (Convolutional Neural Network, CNN) и сеть глубокого убеждения (Deep Belief Network, DBN) были обучены с использованием авторских недавно выпущенных наборов данных штрихкодов. Экспериментальные результаты показывают, что CNN превзошел традиционную классификацию BLAST и наиболее точный классификатор «проект рибосомной базы данных» (Ribosomal Database Project, RDP) по наборам данных, которые имели многие метки, представленные в учебных наборах. При классификации независимого набора данных, а именно, «Топ-50 самых разыскиваемых грибов», CNN и DBN назначили меньше последовательностей, чем BLAST.

В статье Р.Б. Мишра и Х. Джианг [16] применяются вычислительные методы классификаторов машинного обучения и нейронных сетей к набору признаков для интеллектуальной классификации фразы задачи из фразы, не являющейся проблемой, и фразы решения из фразы, не являющейся решением. Анализ показывает, что сети глубокого обучения превосходят классификаторы машинного

обучения. Лучшая модель смогла классифицировать проблемную фразу из несложной фразы с точностью 90% и решающую фразу из нерешающей фразы с точностью 86%.

В свою очередь Б. Кандималла и др. [17] предлагают глубокую внимательную нейронную сеть (Deep Attentive Neural Network, DANN), которая классифицирует научные работы, используя только их рефераты. Сеть обучается с использованием 9 млн рефератов базы «Веб-сайт науки» (Web of Science, WoS). Также используется схема WoS, которая охватывает 104 категории темы. Предложенная сеть состоит из двух двунаправленных рецидивирующих нейронных сетей, за которыми следует слой внимания. Модель сравнивается с опорными линиями. Авторы варьируют архитектуру и текстовое представление.

В работе А. Радхакришнана, М. Белкина и К. Улер [18] идентифицируется и строится явный набор классификаторов нейронных сетей, которые являются последовательными. В более общем плане создана таксономия бесконечно широких и глубоких сетей и показано, что эти модели реализуют один из трех известных классификаторов в зависимости от используемой функции активации:

- 1) один ближайший сосед (предсказания модели даны меткой ближайшего обучающего примера);
- 2) большинство голосов (модельные прогнозы даны меткой класса с наибольшим представительством в обучающем наборе);
- 3) классификаторы ядер в единственном числе (набор классификаторов, содержащих классификаторы, достигающие согласованности).

Результаты подчеркивают преимущество использования глубоких сетей для задач классификации в отличие от задач регрессии, где чрезмерная глубина вредна.

В статье Н. Перишлика и Р. Йовановича [19] рассматривается проблема классификации изображений реальных и фальшивых лиц, поскольку их невозможно различить обычным глазом. Применяются две разные модели архитектуры сверточных нейронных сетей. Первая — это предварительно обученная модель VGG16, где метод обучения переносу применяется в авторском наборе данных. Архитектура второй модели основана на VGG16 и представляет ее меньшую и более легкую версию. В процессе обучения применялись такие методы, как снижение скорости обучения, отсев и периодическая нормализация. Проводится сравнение полученных результатов обеих моделей.

В настоящей работе с помощью нейронных сетей будут моделироваться критерии нематериальной и материальной мотивации топ-менеджмента государственных структур регионов, а также критерии стратегического потенциала региона. Они представлены в *табл. 1*. Таким образом, предполагается, что развитие

стратегического потенциала региона в будущем может повлиять на оба вида мотивации топ-менеджеров. Под материальной мотивацией понимается заработная плата государственного служащего высшего звена, а под нематериальной — его карьерный рост. Целевой функцией при этом является коэффициент естественного прироста населения регионов. Естественно, его положительное значение оценивается позитивно (1 — успех (Success)), а отрицательное — негативно (0 — неудача (Failure)). В итоге получается задача двоичной классификации в обучаемой нейронной сети.

Этапы нейросетевого моделирования мотивации топ-менеджмента государственных структур регионов представлены на *рис. 1*. Опишем их подробнее.

Этап 1 — сбор необходимых данных для построения и обучения нейронной сети. В *табл. 1* собираются данные о местах, занимаемых субъектами РФ по выделенным девяти показателям, а также данные о коэффициентах естественного прироста населения в каждом из 83 анализируемых регионов. При этом изучаются 10 лет с 2010 по 2019 г. В итоге получается 830 наблюдений, что приводит к матрице размерности 830×10 . После этого положительным коэффициентам естественного прироста присваивается категориальное значение 1, то есть Success, а отрицательным — 0, то есть Failure.

Этап 2 — построение и обучение нейронной сети для задачи классификации. Полученная на предыдущем этапе задача двоичной классификации решается в программе Statistica. Для этого методом многократных подвыборок строятся и обучаются нейронные сети с различной архитектурой, то есть числом нейронов на входном и скрытом слоях сети. При этом исследуются как многослойные перцептроны (Multilayer Perceptrones, MLP), так и радиальные базисные функции (Radial Basis Functions, RBF). Затем выбирается сеть с наименьшей ошибкой на обучении, валидации и тесте. Основное внимание уделяется результатам теста. Также принимаются во внимание лифтовые карты (Lift Charts) сетей.

Этап 3 — верификация полученной нейронной сети согласно данным нового периода наблюдения. В качестве такого периода берется следующий — 2020 г. Успешность верификации модели оценивается по всем исходам — Success и Failure. Ошибка на верификации сравнивается с ошибкой на предыдущем этапе.

Этап 4 — определение регионов-лидеров и сегментов планируемых параметров модели. Данные, прогнозируемые нейронной сетью, сравниваются с исходными данными *табл. 1*. При этом нас интересуют только те 20 регионов, в которых находятся территориальные инновационные кластеры, утвержденные Правительством РФ. Принимаются во внимание только те случаи в матрице размерностью 830×10 , где прогнозное значение Success совпадает с фактическим, так как мы создаем модель, прогнозирующую прирост населения в регионах. По этим случаям определяются те регионы-лидеры, которые наблюдаются в матрице чаще. Затем для

них по рассматриваемым случаям устанавливается сегмент для каждого из девяти параметров модели. После этого сегменты для всех наиболее часто встречающихся регионов-лидеров объединяются также для каждого из девяти параметров модели.

Здесь же определяются наиболее важные из девяти переменных (параметров), что позволит получить важную дополнительную информацию как о самой модели, так и о важности планируемых показателей для мотивации топ-менеджмента регионов.

Этап 5 — оценка соответствия изучаемого региона планируемым параметрам модели. Фактические значения мест, занимаемых субъектом РФ, сравниваются с планируемыми сегментами, которые получены на предыдущем этапе. Такое сравнение проводится по всем девяти параметрам по двум последним годам — 2019 и 2020 гг. Это позволяет определить, как следует мотивировать государственных служащих высшего звена в регионе согласно результатам развития региона в 2019 и 2020 гг. Также оцениваются стратегические возможности региона, что может в ближайшем будущем отразиться на материальной и нематериальной мотивации топ-менеджеров государственной структуры региона.

Если полученная нейронная сеть показала маленькую ошибку на этапах 2 и 3, то ее можно применять и в последующие годы. Если же по мнению разработчика нейронной сети ошибка недостаточно мала, то модель уточняется с помощью включения данных новых лет в изначальную выборку. Для этого строится и обучается новая нейронная сеть уже на большей выборке.

Рассмотрим процесс нейросетевого моделирования мотивации топ-менеджмента государственных структур регионов на представленном в *табл. 1* примере. Окончательные выводы сделаем для Нижегородской области, где есть два территориальных инновационных кластера.

Этап 1 — сбор необходимых данных для построения и обучения нейронной сети. Эти данные собраны в *табл. 1* для 83 регионов и 10 лет с 2010 по 2019 г. Коэффициентам естественного прироста присвоены категориальные значения 1 (Success) или 0 (Failure).

Этап 2 — построение и обучение нейронной сети для задачи классификации. В программе Statistica методом многократных подвыборок построены и обучены нейронные сети с разным числом нейронов на входном и скрытом слоях сети. Выбрана сеть с наименьшей ошибкой на обучении, валидации и тесте (*рис. 2*). Это многослойный перцептрон (MLP) с 9 нейронами на входном слое и 20 нейронами на внутреннем слое сети.

Этап 3 — верификация полученной нейронной сети согласно данным нового периода наблюдения. В качестве периода для верификации берется следующий — 2020 г. Матрица достоверности выбранной нейронной сети на верификации

показана на *рис. 3*. Общая ошибка классификации сети составила 12%, что несколько больше 5,4% (*рис. 2*) на обучении, валидации и тесте сети. Поэтому считаем, что выбранная нейронная сеть дает достаточно качественный прогноз будущих значений коэффициента естественного прироста населения в плане прироста или убыли населения регионов.

Этап 4 — определение регионов-лидеров и сегментов планируемых параметров модели. Здесь сначала выбираются только те 20 регионов, в которых находятся территориальные инновационные кластеры, утвержденные Правительством РФ. Это Москва, Санкт-Петербург, Калужская, Московская, Архангельская, Ленинградская, Нижегородская, Самарская, Ульяновская, Свердловская, Кемеровская, Новосибирская, Томская области, республики Башкортостан, Мордовия, Татарстан, Алтай, Пермский, Красноярский, Хабаровский края. Далее находим в *табл. 1* те случаи, где прогнозируемое сетью значение Success совпадает с фактическим. Чаще это наблюдается для Москвы, Республики Татарстан и Томской области (*табл. 2*). Затем по данным *табл. 1* для этих регионов — лидеров по рассматриваемым случаям определяется сегмент для каждого из 9 параметров модели. После этого сегменты для регионов-лидеров объединяются также для каждого из 9 параметров модели в *табл. 2*.

Чувствительность построенной модели к входным переменным показана на *рис. 4*. Это определяет важность переменных для анализа и прогноза коэффициента естественного прироста населения в регионах (*табл. 2*). Наиболее важными переменными являются общая площадь жилых помещений на душу населения (x_5), поступление налогов на душу населения (x_7) и среднедушевые денежные доходы в месяц (x_4). Именно они в первую очередь определяют, будет ли прирост населения в том или ином регионе. Следовательно, соответствие их значений сегментам для регионов-лидеров должно прежде всего определять мотивацию руководителей высшего звена в правительствах регионов. Поэтому в *табл. 2* эти сегменты отдельно подчеркнуты.

Этап 5 — оценка соответствия изучаемого региона планируемым параметрам модели. В *табл. 3* сравним фактические значения мест, занимаемых Нижегородской областью, с планируемыми сегментами, которые получены на предыдущем этапе в *табл. 2*. Совпадения отдельно подчеркнуты. Это означает, что в Нижегородской области топ-менеджеров по результатам 2019 и 2020 гг. следует поощрять только материально. Но в 2020 г. ситуация немного изменилась в лучшую сторону, то есть топ-менеджеров можно начать поощрять еще и нематериально. Стратегический потенциал региона развит слабо.

Сравним точность модели в рассмотренном примере с точностью, которая была получена в модели С.Н. Яшина, Е.В. Кошелева и Д.А. Суханова¹ с применением логистической регрессии. Там суммарная ошибка на верификации по функциям нематериальной, материальной мотивации и стратегического потенциала составила 39%. В нашем же случае данная ошибка составила лишь 12% (рис. 3). Это говорит о том, что нейронные сети позволяют достичь гораздо большей точности прогноза.

В заключение обозначим наиболее важные выводы исследования.

1. С помощью нейронных сетей возможно моделировать критерии материальной и нематериальной мотивации топ-менеджмента государственных структур регионов, а также критерии стратегического потенциала региона. Под материальной мотивацией понимается заработная плата государственного служащего высшего звена, а под нематериальной — его карьерный рост. Целевой функцией при этом является коэффициент естественного прироста населения регионов.
2. Если полученная нейронная сеть показала маленькую ошибку, то ее можно применять и в последующие годы. Если же по мнению разработчика нейронной сети ошибка недостаточно мала, то модель уточняется с помощью включения данных новых лет в изначальную выборку. Для этого строится и обучается новая нейронная сеть уже на большей выборке.
3. Представленная модель протестирована для Нижегородской области. Получено, что топ-менеджеров государственных структур данного региона по результатам 2019 и 2020 гг. следует поощрять только материально. Но в 2020 г. ситуация немного изменилась в лучшую сторону, то есть топ-менеджеров можно начать поощрять еще и нематериально. Стратегический потенциал региона развит слабо.

Полученные результаты могут быть полезны государственным структурам регионов для разработки конструктивной системы материальной и нематериальной мотивации своих топ-менеджеров.

¹ Яшин С.Н., Кошелев Е.В., Суханов Д.А. Моделирование мотивации топ-менеджмента управляющих структур регионов с применением логистической регрессии // *Финансы и кредит*. 2023. Т. 29. № 2. С. 262–289. URL: <https://doi.org/10.24891/fc.29.2.262>

Таблица 1
Данные для построения и обучения нейронных сетей

Table 1
Data for building and training neural networks

Показатель		1. Белгородская область	2. Брянская область	3. Владимирская область	...	83. Чукотский АО
<i>Нематериальная мотивация</i>						
ВРП на душу населения	x_1	19	62	48	...	3
Инвестиции в основной капитал на душу населения	x_2	32	67	63	...	3
Затраты организаций на инновации на душу населения	x_3	17	51	25	...	69
<i>Материальная мотивация</i>						
Среднедушевые денежные доходы (в месяц)	x_4	23	43	59	...	2
Общая площадь жилых помещений на душу населения	x_5	6	15	16	...	69
Удельный вес автодорог с твердым покрытием	x_6	10	56	52	...	83
<i>Стратегический потенциал</i>						
Поступление налогов на душу населения	x_7	34	60	42	...	5
Уровень занятости	x_8	16	54	30	...	1
Численность студентов на 10 000 чел. населения	x_9	18	52	54	...	83
Коэффициент естественного прироста населения на 1 000 человек	$y \pm$	-7,6 0	-9 0	-10,8 0	...	0,4 1

Источник: Федеральная служба государственной статистики. URL: <https://www.gks.ru>

Source: The Federal State Statistics Service data. URL: <https://www.gks.ru>

Таблица 2
Диапазоны мест регионов — лидеров

Table 2
Ranges of places of leading regions

Показатель	г. Москва	Республика Татарстан	Томская область	Итог по регионам	Важность переменных
<i>Нематериальная мотивация</i>					
x ₁	[4; 6]	[12; 16]	[14; 22]	[4; 22]	4
x ₂	[10; 27]	[9; 19]	[18; 33]	[9; 33]	8
x ₃	[3; 12]	[3; 12]	[11; 30]	[3; 30]	9
<i>Материальная мотивация</i>					
x ₄	[2; 4]	[16; 20]	[38; 52]	[2; 52]	3
x ₅	[76; 82]	[36; 43]	[59; 65]	[36; 82]	1
x ₆	[1; 3]	[34; 57]	[42; 61]	[1; 61]	6
<i>Стратегический потенциал</i>					
x ₇	[5; 6]	[13; 17]	[8; 12]	[5; 17]	2
x ₈	[3; 6]	[10; 14]	[41; 79]	[3; 79]	5
x ₉	[1; 2]	[6; 10]	[2; 3]	[1; 10]	7
Частота Success	8 раз	8 раз	8 раз	—	—

Источник: авторская разработка

Source: Authoring

Таблица 3
Результаты работы топ-менеджмента государственных структур Нижегородской области

Table 3
Results of government agencies' top management of the Nizhny Novgorod Oblast

Показатель	2020 г.	2019 г.
<i>Нематериальная мотивация</i>		
x ₁	36 [4; 22]	34 [4; 22]
x ₂	25 [9; 33]	41 [9; 33]
x ₃	2 [3; 30]	2 [3; 30]
<i>Материальная мотивация</i>		
x ₄	21 [2; 52]	20 [2; 52]
x ₅	32 [36; 82]	33 [36; 82]
x ₆	50 [1; 61]	49 [1; 61]
<i>Стратегический потенциал</i>		
x ₇	30 [5; 17]	31 [5; 17]
x ₈	13 [3; 79]	16 [3; 79]
x ₉	29 [1; 10]	29 [1; 10]
Коэффициент у	-8,6	-5,6

Источник: авторская разработка

Source: Authoring

Рисунок 1

Этапы нейросетевого моделирования мотивации топ-менеджмента государственных структур регионов

Figure 1

Stages of neural network modeling of motivation for top management of government agencies of regions



Источник: авторская разработка

Source: Authoring

Рисунок 2

Матрица достоверности лучшей нейронной сети

Figure 2

Confidence matrix of the best neural network

SUCCESS (Classification summary) (Regions_2010-2019.sta)				
Samples: Train, Test, Validation				
		SUCCESS-FAILURE	SUCCESS-SUCCESS	SUCCESS-All
26.MLP 9-20-2	Total	507,0000	323,0000	830,0000
	Correct	481,0000	304,0000	785,0000
	Incorrect	26,0000	19,0000	45,0000
	Correct (%)	94,8718	94,1176	94,5783
	Incorrect (%)	5,1282	5,8824	5,4217

Источник: авторская разработка

Source: Authoring

Рисунок 3

Матрица достоверности нейронной сети на верификации

Figure 3

Confidence matrix of the neural network for verification

SUCCESS (Classification summary) (Regions_2020.sta)				
Samples: Test				
		SUCCESS-FAILURE	SUCCESS-SUCCESS	SUCCESS-All
1.MLP 9-20-2	Total	69,00000	14,00000	83,00000
	Correct	60,00000	13,00000	73,00000
	Incorrect	9,00000	1,00000	10,00000
	Correct (%)	86,95652	92,85714	87,95181
	Incorrect (%)	13,04348	7,14286	12,04819

Источник: авторская разработка

Source: Authoring

Рисунок 4**Чувствительность модели к входным переменным****Figure 4****Model sensitivity to input variables**

Sensitivity analysis (Regions_2010-2019.sta)									
Samples: Train, Test, Validation									
Networks	Var5	Var7	Var4	Var1	Var9	Var6	Var8	Var2	Var3
26.MLP 9-20-2	16.033251	12,11507	7,969069	5,608864	4,933241	4,673952	2,979064	2,677088	2,357610

Источник: авторская разработка

Source: Authoring

Список литературы

1. *Munna A.* Strategic Management, Leadership and Staff Motivation: Literature Review. *International Education and Culture Studies*, 2021, vol. 1, no. 1, pp. 21–29. URL: <https://repository.uwtsd.ac.uk/id/eprint/1857>
2. *Christensen R., Paarlberg L., Perry J.* Public Service Motivation Research: Lessons for Practice. *Public Administration Review*, 2017, vol. 77, iss. 4, pp. 529–542. URL: <https://doi.org/10.1111/puar.12796>
3. *Serhan C., Achy E., Nicolas E.* Understanding Public Sector Employees' Motivation: What Makes Them Inspired? *International Journal of Human Resource Studies*, 2018, vol. 8, no. 1, pp. 249–273. URL: <https://doi.org/10.5296/ijhrs.v8i1.12758>
4. *Ritz A., Vandenabeele W., Vogel D.* Public Service Motivation and Individual Job Performance. In: *Leisink P. et al. (eds) Managing for Public Service Performance: How People and Values Make a Difference.* Oxford, Oxford University Press, 2021, pp. 254–277. URL: <https://doi.org/10.1093/oso/9780192893420.003.0014>
5. *Heo S., Lee J.H.* Fault Detection and Classification Using Artificial Neural Networks. *IFAC-PapersOnLine*, 2018, vol. 51, iss. 18, pp. 470–475. URL: <https://doi.org/10.1016/j.ifacol.2018.09.380>
6. *Sysoev A., Mayorov V.* Texterra at SemEval-2018 Task 7: Exploiting Syntactic Information for Relation Extraction and Classification in Scientific Papers. *Proceedings of the 12th International Workshop on Semantic Evaluation, New Orleans, Louisiana, 2018*, pp. 821–825.
7. *Adhikari A., Ram A., Tang R., Lin J.* Rethinking Complex Neural Network Architectures for Document Classification. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, vol. 1 (Long and Short Papers), Minneapolis, Minnesota, 2019*, pp. 4046–4051.

8. *Ech-Chouyyekh M., Omara H., Lazaar M.* Scientific Paper Classification Using Convolutional Neural Networks. *BDIoT'19: Proceedings of the 4th International Conference on Big Data and Internet of Things*, 2019, pp. 1–6.
URL: <https://doi.org/10.1145/3372938.3372951>
9. *Romanov A., Lomotin K., Kozlova E.* Application of Natural Language Processing Algorithms to the Task of Automatic Classification of Russian Scientific Texts. *Data Science Journal*, 2019, vol. 18, no. 37, pp. 1–17.
URL: <https://doi.org/10.5334/dsj-2019-037>
10. *Venkataramanan A., Agarwal P.* Plant Disease Detection and Classification Using Deep Neural Networks. *International Journal on Computer Science and Engineering (IJCSE)*, 2019, vol. 11, no. 8, pp. 40–46.
11. *Korde S.K., Munda M.J., Chintamani Y.B. et al.* Image Classification using Deep Learning. *International Journal of Trend in Scientific Research and Development*, 2020, vol. 4, iss. 4, pp. 1648–1650.
12. *Aversa R., Coronica P., De Nobili C., Cozzini S.* Deep Learning, Feature Learning, and Clustering Analysis for SEM Image Classification. *Data Intelligence*, 2020, vol. 2, iss. 4, pp. 513–528. URL: https://doi.org/10.1162/dint_a_00062
13. *Rajendran R., Samuel L.* Satellite Image Classification with Deep Learning: Survey. *International Journal of Trend in Scientific Research and Development*, 2020 vol. 4, iss. 2, pp. 583–587. URL: <https://www.ijtsrd.com/papers/ijtsrd30031.pdf>
14. *Nithya R.* Training the Image Classifier with and without Data Augmentation. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology (IJSRCSEIT)*, 2020, vol. 6, iss. 2, pp. 172–178.
URL: <https://ijsrcseit.com/CSEIT206245>
15. *Vu D., Groenewald M., Verkley G.* Convolutional Neural Networks Improve Fungal Classification. *Scientific Reports*, 2020, vol. 10, no. 12628.
URL: <https://doi.org/10.1038/s41598-020-69245-y>
16. *Mishra R.B., Jiang H.* Classification of Problem and Solution Strings in Scientific Texts: Evaluation of the Effectiveness of Machine Learning Classifiers and Deep Neural Networks. *Applied Science*, 2021, vol. 11(21).
URL: <https://doi.org/10.3390/app11219997>
17. *Kandimalla B., Rohatgi S., Wu J., Giles C.L.* Large Scale Subject Category Classification of Scholarly Papers with Deep Attentive Neural Networks. *Frontiers in Research Metrics and Analytics*, 2021, vol. 5.
URL: <https://doi.org/10.3389/frma.2020.600382>

18. Radhakrishnan A., Belkin M., Uhler C. Wide and Deep Neural Networks Achieve Consistency for Classification. *Proceedings of the National Academy of Sciences (PNAS)*, 2023, vol. 120, no. 14. URL: <https://doi.org/10.1073/pnas.2208779120>
19. Perišić N., Jovanović R. Convolutional Neural Networks for Real and Fake Face Classification. In: *Sinteza 2022 – International Scientific Conference on Information Technology and Data Related Research*, Belgrade, 2022, pp. 29–35. URL: <https://doi.org/10.15308/Sinteza-2022-29-35>

Информация о конфликте интересов

Мы, авторы данной статьи, со всей ответственностью заявляем о частичном и полном отсутствии фактического или потенциального конфликта интересов с какой бы то ни было третьей стороной, который может возникнуть вследствие публикации данной статьи. Настоящее заявление относится к проведению научной работы, сбору и обработке данных, написанию и подготовке статьи, принятию решения о публикации рукописи.

NEURAL NETWORK MODELING OF MOTIVATION FOR GOVERNMENT AGENCIES' TOP MANAGEMENT OF REGIONS AS A CLASSIFICATION PROBLEM

Sergei N. YASHIN^{a,*}, Egor V. KOSHELEV^b, Aleksandr V. KUPTSOV^c

^a National Research Lobachevsky State University of Nizhny Novgorod (UNN),
Nizhny Novgorod, Russian Federation
jashinsn@yandex.ru
<https://orcid.org/0000-0002-7182-2808>

^b National Research Lobachevsky State University of Nizhny Novgorod (UNN),
Nizhny Novgorod, Russian Federation
ekoshelev@yandex.ru
<https://orcid.org/0000-0001-5290-7913>

^c National Research Lobachevsky State University of Nizhny Novgorod (UNN),
Nizhny Novgorod, Russian Federation
kav191982@yandex.rue
ORCID: not available

* Corresponding author

Article history:

Article No. 252/2023
Received 1 June 2023
Received in revised form
19 June 2023
Accepted 3 July 2023
Available online
30 October 2023

JEL classification: C38,
C45, H83, O21, R58

Keywords: top
management, motivation,
neural networks,
classification

Abstract

Subject. The study deals with modeling the motivation of top managers of government agencies in regions to align the interests of people and the State.

Objectives. The purpose of the study is to create a neural network model of motivation for top management of regional government institutions for a classification problem.

Methods. Using neural networks, we simulate criteria for non-financial and financial motivation of the said top management, and criteria for strategic potential of regions. Financial motivation is defined as the salary of a senior civil servant, and non-financial motivation as his or her career growth. At the same time, the target function is a coefficient of natural population growth in regions, its positive value is assessed positively, and negative value negatively. As a result, the problem of binary classification in the trained neural network is solved.

Results. Comparing the accuracy of the model in the considered example with accuracy that was obtained earlier, using logistic regression, we note that in the previous model, the total error in verification by the functions of non-financial and financial motivation and strategic potential was 39%. In our case, this error was only 12%. This suggests that neural networks enable to achieve much more accurate forecasting.

Conclusions. The findings could be useful for regional government agencies to develop a constructive system of non-financial and financial motivation for their top managers.

© Publishing house FINANCE and CREDIT, 2023

Please cite this article as: Yashin S.N., Koshelev E.V., Kuptsov A.V. Neural Network Modeling of Motivation for Government Agencies' Top Management of Regions as a Classification Problem. *Finance and Credit*, 2023, vol. 29, iss. 10, pp. 2253–2273.
<https://doi.org/10.24891/fc.29.10.2253>

Acknowledgments

The study was performed as part of implementation of Strategic Academic Leadership Program “Priority 2030”, project H-426-99_2022-2023, *Socio-economic Models and Technologies for Creative Human Capital Development in the Innovation Society*.

References

1. Munna A. Strategic Management, Leadership and Staff Motivation: Literature Review. *International Education and Culture Studies*, 2021, vol. 1, no. 1, pp. 21–29.
URL: <https://repository.uwtsd.ac.uk/id/eprint/1857>
2. Christensen R., Paarlberg L., Perry J. Public Service Motivation Research: Lessons for Practice. *Public Administration Review*, 2017, vol. 77, iss. 4, pp. 529–542.
URL: <https://doi.org/10.1111/puar.12796>
3. Serhan C., Achy E., Nicolas E. Understanding Public Sector Employees’ Motivation: What Makes Them Inspired? *International Journal of Human Resource Studies*, 2018, vol. 8, no. 1, pp. 249–273. URL: <https://doi.org/10.5296/ijhrs.v8i1.12758>
4. Ritz A., Vandenabeele W., Vogel D. Public Service Motivation and Individual Job Performance. In: Leisink P. et al. (eds) *Managing for Public Service Performance: How People and Values Make a Difference*. Oxford, Oxford University Press, 2021, pp. 254–277. URL: <https://doi.org/10.1093/oso/9780192893420.003.0014>
5. Heo S., Lee J.H. Fault Detection and Classification Using Artificial Neural Networks. *IFAC-PapersOnLine*, 2018, vol. 51, iss. 18, pp. 470–475.
URL: <https://doi.org/10.1016/j.ifacol.2018.09.380>
6. Sysoev A., Mayorov V. Texterra at SemEval-2018 Task 7: Exploiting Syntactic Information for Relation Extraction and Classification in Scientific Papers. *Proceedings of the 12th International Workshop on Semantic Evaluation, New Orleans, Louisiana, 2018*, pp. 821–825.
7. Adhikari A., Ram A., Tang R., Lin J. Rethinking Complex Neural Network Architectures for Document Classification. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, vol. 1 (Long and Short Papers), Minneapolis, Minnesota, 2019*, pp. 4046–4051.
8. Ech-Chouyyekh M., Omara H., Lazaar M. Scientific Paper Classification Using Convolutional Neural Networks. *BDIoT'19: Proceedings of the 4th International Conference on Big Data and Internet of Things, 2019*, pp. 1–6.
URL: <https://doi.org/10.1145/3372938.3372951>

9. Romanov A., Lomotin K., Kozlova E. Application of Natural Language Processing Algorithms to the Task of Automatic Classification of Russian Scientific Texts. *Data Science Journal*, 2019, vol. 18, no. 37, pp. 1–17.
URL: <https://doi.org/10.5334/dsj-2019-037>
10. Venkataramanan A., Agarwal P. Plant Disease Detection and Classification Using Deep Neural Networks. *International Journal on Computer Science and Engineering (IJCSE)*, 2019, vol. 11, no. 8, pp. 40–46.
11. Korde S.K., Munda M.J., Chintamani Y.B. et al. Image Classification using Deep Learning. *International Journal of Trend in Scientific Research and Development*, 2020, vol. 4, iss. 4, pp. 1648–1650.
12. Aversa R., Coronica P., De Nobili C., Cozzini S. Deep Learning, Feature Learning, and Clustering Analysis for SEM Image Classification. *Data Intelligence*, 2020, vol. 2, iss. 4, pp. 513–528. URL: https://doi.org/10.1162/dint_a_00062
13. Rajendran R., Samuel L. Satellite Image Classification with Deep Learning: Survey. *International Journal of Trend in Scientific Research and Development*, 2020, vol. 4, iss. 2, pp. 583–587. URL: <https://www.ijtsrd.com/papers/ijtsrd30031.pdf>
14. Nithya R. Training the Image Classifier with and without Data Augmentation. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology (IJSRCSEIT)*, 2020, vol. 6, iss. 2, pp. 172–178.
URL: <https://ijsrcseit.com/CSEIT206245>
15. Vu D., Groenewald M., Verkley G. Convolutional Neural Networks Improve Fungal Classification. *Scientific Reports*, 2020, vol. 10, no. 12628.
URL: <https://doi.org/10.1038/s41598-020-69245-y>
16. Mishra R.B., Jiang H. Classification of Problem and Solution Strings in Scientific Texts: Evaluation of the Effectiveness of Machine Learning Classifiers and Deep Neural Networks. *Applied Sciences*, 2021, vol. 11(21).
URL: <https://doi.org/10.3390/app11219997>
17. Kandimalla B., Rohatgi S., Wu J., Giles C.L. Large Scale Subject Category Classification of Scholarly Papers with Deep Attentive Neural Networks. *Frontiers in Research Metrics and Analytics*, 2021, vol. 5.
URL: <https://doi.org/10.3389/frma.2020.600382>
18. Radhakrishnan A., Belkin M., Uhler C. Wide and Deep Neural Networks Achieve Consistency for Classification. *Proceedings of the National Academy of Sciences (PNAS)*, 2023, vol. 120, no. 14. URL: <https://doi.org/10.1073/pnas.2208779120>
19. Perišić N., Jovanović R. Convolutional Neural Networks for Real and Fake Face Classification. *Sinteza 2022 – International Scientific Conference on Information*

Technology and Data Related Research, Belgrade, 2022, pp. 29–35.

URL: <https://doi.org/10.15308/Sinteza-2022-29-35>

Conflict-of-interest notification

We, the authors of this article, bindingly and explicitly declare of the partial and total lack of actual or potential conflict of interest with any other third party whatsoever, which may arise as a result of the publication of this article. This statement relates to the study, data collection and interpretation, writing and preparation of the article, and the decision to submit the manuscript for publication.