



РЕГИОНАЛЬНАЯ И МУНИЦИПАЛЬНАЯ ЭКОНОМИКА REGIONAL AND MUNICIPAL ECONOMY

УДК 332.1+004.8(470+571)

DOI 10.52575/2687-0932-2025-52-1-5-18

Дискриминация отдельных российских регионов в социально-экономической кластеризации на основе нейросети Кохонена

Блануца В.И.

Институт географии им. В.Б. Сочавы Сибирского отделения РАН
Россия, 664033, Иркутская область, г. Иркутск, ул. Улан-Баторская, д. 1
blanutsa@list.ru

Аннотация. Статья посвящена обнаружению алгоритмической предвзятости в результатах социально-экономической кластеризации российских регионов на основе нейросети Кохонена, опубликованных в научных журналах. Идентифицированы потенциально предвзятые операции в самоорганизующихся картах. Выявлено 65 статей по нейросетевой и 604 статьи по традиционной социально-экономической кластеризации регионов. Предложено разделить массивы статей по нейросетевой и традиционной кластеризации на три корпуса публикаций, посвященных группировке всех российских регионов, регионов одного федерального округа и выборке регионов. Основные выводы сделаны для корпуса всех регионов. В результате сопоставления предвзятых операций с отечественным опытом социально-экономической кластеризации регионов обнаружены три вида пространственной алгоритмической предвзятости в самоорганизующихся картах, которые с некоторой условностью названы региональной сегрегацией (исключение региона из кластеризации), кластерным сжатием (ограничение числа кластеров) и диапазоным смещением (трансформация размера кластеров). Показано, что по сравнению с традиционной кластеризацией применение нейросетевого алгоритма ведет к образованию кластеров с как можно большим количеством регионов. Приведены перечни потенциально дискриминируемых регионов для двух существующих кластерных решений. Представлены пять направлений дальнейших исследований. Практическая значимость связана с обнаружением недостатков существующей методики для построения алгоритма справедливой нейросетевой кластеризации российских регионов по социально-экономическим данным.

Ключевые слова: региональное социально-экономическое развитие, кластерный анализ, самоорганизующиеся карты Кохонена, пространственная алгоритмическая предвзятость, дискриминируемый регион, справедливая кластеризация, Российская Федерация

Благодарности: исследование выполнено за счет средств государственного задания (№ регистрации темы АААА-А21-121012190018-2).

Для цитирования: Блануца В.И. 2025. Дискриминация отдельных российских регионов в социально-экономической кластеризации на основе нейросети Кохонена. *Экономика. Информатика*, 52(1): 5–18. DOI 10.52575/2687-0932-2025-52-1-5-18



Discrimination of Individual Russian Regions in Socio-Economic Clustering Based on the Kohonen Neural Network

Viktor I. Blanutsa

V.B. Sochava Institute of Geography, Siberian Branch, Russian Academy of Sciences
1 Ulan-Batorskaya St., Irkutsk, Irkutsk Region, 664033, Russia
blanutsa@list.ru

Abstract. The article is devoted to the detection of algorithmic bias in the results of Russian regions' socio-economic clustering based on the Kohonen neural network which have been published in scientific journals. The study reveals potentially biased operations in self-organizing maps. Sixty-five articles on neural network and 604 articles on traditional socio-economic clustering of regions have been found. The author proposes that the arrays of articles on neural network and traditional clustering should be divided into three bodies of publications: those devoted to all Russian regions, the ones focused on regions of the same federal district, and the papers describing a sample of regions. The main conclusions are drawn for the corpus of articles that is focused on all regions. As a result of comparing biased operations with the domestic experience of socio-economic clustering of regions, three types of spatial algorithmic bias were found in self-organizing maps. These may be conditionally described as regional segregation (exclusion of a region from clustering), cluster compression (limitation of the number of clusters) and range bias (transformation of cluster size). It is shown that, compared with traditional clustering, the use of a neural network algorithm leads to the formation of clusters with as many regions as possible. The author provides lists of potentially discriminated regions for two existing cluster solutions and presents five areas of further research. The practical significance is associated with the discovery of shortcomings in the existing methodology for constructing an algorithm for fair neural network clustering of Russian regions based on socio-economic data.

Keywords: regional socio-economic development, cluster analysis, Kohonen self-organizing maps, spatial algorithmic bias, discriminated region, fair clustering, Russian Federation

Acknowledgements: the study was carried out at the expense of the state task (topic registration No. AAAA21-121012190018-2).

For citation: Blanutsa V.I. 2025. Discrimination of Individual Russian Regions in Socio-Economic Clustering Based on the Kohonen Neural Network. *Economics. Information technologies*, 52(1): 5–18 (in Russian). DOI 10.52575/2687-0932-2025-52-1-5-18

Введение

Социально-экономическое развитие регионов является сложным, многомерным процессом, измерение и прогнозирование которого опирается на множество показателей. Для обработки исходных данных применялись различные алгоритмы многомерного статистического анализа, в том числе кластерный анализ [Soares, Coutinho, 2010; Lypez-Villuendas, del Campo, 2023]. Среди способов обнаружения кластеров можно отметить две основные группы алгоритмов – традиционную [Mirkin, 1996; Giordani et al., 2020] и нейросетевую [Ros et al., 2024; Wei et al., 2024] кластеризацию. Во второй группе наиболее часто [Yin, 2008] использовались самоорганизующиеся карты (Self-Organizing Maps, SOM), предложенные финским исследователем Теуво Кохоненом [Kohonen, 1982; 2001]. Эта искусственная нейронная сеть позволяла идентифицировать группы регионов с разным уровнем социально-экономического развития [Kourtiti et al., 2012; Carboni, Russu, 2015].

Для кластеризации на основе SOM разработано программное обеспечение (Deductor SOMap Analyzer, STATISTICA Automated Neural Networks, Viscovery SOMine и др.), позволяющее свести к минимуму субъективные мнения исследователей. Тем не менее была обнаружена «алгоритмическая предвзятость», когда «алгоритм неравномерно распределяет выгоды и бремя между различными индивидами или группами» [Kordzadeh, Ghasemaghaei, 2022, p. 394]. При машинном обучении зафиксирована дискриминация граждан по языку,

национальности, расе, полу, возрасту, образованию и благосостоянию [Jackson, 2021; Van Giffen et al., 2022]. Недавно обнаружена «пространственная алгоритмическая предвзятость» [Блануца, 2024] как несправедливость по отношению к отдельным территориям (регионам), возникающая в результате использования алгоритма (исследовался традиционный кластерный анализ без оценки предвзятости SOM).

Целью нашего исследования стало обнаружение алгоритмической предвзятости в результатах социально-экономической кластеризации российских регионов на основе нейросети Кохонена, опубликованных в научных журналах. Для достижения этой цели потребовалось решить следующие задачи: идентифицировать потенциально предвзятые операции в алгоритме SOM; сформировать массив статей по социально-экономической кластеризации субъектов (регионов) Российской Федерации на основе SOM; сравнить его с массивом статей по традиционной кластеризации российских регионов, представленном в [Блануца, 2024], и выделить основные элементы SOM, предвзято относящиеся к кластеризации регионов; выявить реально и потенциально дискриминируемые регионы России.

Объекты и методы исследования

Алгоритм SOM и его модификации довольно подробно описаны в специальной литературе [Kohonen, 2001; Agarwal, Skupin, 2008; Yin, 2008]. Рассматриваемая нейросеть Кохонена основана на «обучении без учителя» (существуют также сети векторного квантования, обучаемые с учителем), но не является полностью автономной системой искусственного интеллекта, так как исследователи (пользователи SOM) вводят исходные данные и настраивают некоторые параметры алгоритма. В наиболее общем виде алгоритм включает следующие действия (операции): формирование матрицы данных (множество регионов, каждый из которых имеет определенные значения заданных показателей); нормализация исходных данных (как правило, перевод всех значений в интервал от 0 до 1); введение меры сходства (расстояния) между регионами (обычно используется евклидово расстояние) и преобразование нормализованных данных в матрицу расстояний; определение числа кластеров (задается исследователем или рассчитывается по специальным критериям); разделение входных данных на обучающее и тестовое множество (в некоторых программах по умолчанию это, соответственно, 95 % и 5 %); задание количества и формы – прямоугольная или шестиугольная – ячеек карты, функции соседства, условия остановки обучения (количество эпох или достижение установленных пределов) и других параметров SOM; запуск процесса обучения и кластеризации; визуализация полученных результатов в виде двумерной карты распределения регионов по кластерам.

Архитектура нейросети представлена двумя слоями узлов (нейронов) – входным и выходным – и связями между нейронами обоих слоев. Обучение заключается в постепенном (итерационном) изменении весов связей между входными и выходными узлами с учетом соседей. На выходе получаются скопления регионов вокруг центров заданных кластеров. При этом регионы, близко расположенные друг к другу во входном многомерном признаковом пространстве, также близко расположены в выходном двумерном пространстве. Концепция формирования кластеров с помощью SOM совпадает (без учета особенностей машинного обучения) с концепцией образования кластеров посредством метода k-средних в традиционном кластерном анализе [Khasanah, 2016], что позволяет проецировать предвзятости последнего алгоритма на SOM. Анализ публикаций по справедливому кластерному анализу [Chabra et al., 2021; Gupta et al., 2023], алгоритмам машинного обучения [Van Giffen et al., 2022; Nishant et al., 2024], нейросетевой [Ros et al., 2024; Wei et al., 2024] и традиционной [Lorimer et al., 2017] кластеризации позволил установить, что алгоритмическая предвзятость проявляется при формировании матрицы исходных данных, обработке данных и интерпретации полученных результатов.

Если рассматривать только обработку исходных данных с помощью SOM, то предвзятость может возникнуть в результате неправильной настройки параметров



алгоритма, отсутствия понимания латентной структуры входного многомерного пространства и проявления внутренних (встроенных) дефектов нейросетевой кластеризации как «черного ящика» (известен только вход и выход). Среди настраиваемых параметров SOM наибольшее влияние на конечный результат оказывают количество кластеров, мера многомерного расстояния между объектами (регионами) и радиус обучения [Agarwal, Skupin, 2008; Yin, 2008]. Латентная структура может принимать выпуклые (гиперсферы, эллипсоиды, кубоиды и др.) и невыпуклые (кольцеобразные, крестообразные и др.) формы [Lorimer et al., 2017; Hadi, 2022]. Алгоритм SOM предназначен для работы со сферическими формами [Schmidt et al., 2011], а при обработке исходных данных с другими формами получится предвзятая кластеризация [Lorimer et al., 2017]. Наибольшую сложность представляет выявление предвзятости в алгоритмах типа «черного ящика», для чего необходимо сравнение с аналогичными результатами работы понятного алгоритма («белого ящика»).

Для поиска статей с результатами социально-экономической кластеризации российских регионов использовался авторский алгоритм обнаружения необходимых публикаций в библиографических базах данных с помощью итерационного расширения семантического поля в процессе машинного обучения [Блануца, 2020]. По SOM-обусловленной социально-экономической кластеризации российских регионов выявлено 65 статей, опубликованных в 2003–2023 гг. Несмотря на значительные колебания ежегодного количества статей (рис. 1, А), наблюдался рост научного интереса к применению SOM для выделения групп регионов со сходными значениями социально-экономических показателей (в 2014–2023 гг. опубликовано в 5,5 раза больше статей, чем в 2003–2013 гг.). Для сравнения использовался ранее выявленный массив статей по традиционному кластерному анализу регионов России [Блануца, 2024], в который вошли 604 статьи (2004–2023 гг.). Их распределение имело более выраженный восходящий тренд (рис. 1, Б) с меньшим различием между десятилетиями (в 2014–2023 гг. опубликовано в 3,9 раза больше статей, чем в 2004–2013 гг.). Поскольку в некоторых публикациях приводилось по несколько результатов кластеризации (по разным годам, наборам показателей и другим основаниям), то будем учитывать не только статьи, но и результаты – 130 в нейросетевом и 781 в традиционном массиве.

Статьи первого массива опубликованы в 40 журналах. Больше всего публикаций размещено в журналах «Вестник Нижегородского университета им. Н.И. Лобачевского. Серия: Социальные науки» (7 статей), «Развитие и безопасность» (6) и «Экономический анализ: теория и практика» (5). Авторами статей стали 75 исследователей из 27 организаций, среди которых выделялись Нижегородский государственный университет им. Н.И. Лобачевского (24,51 статьи; если были авторы из разных организаций, то статья как единица счета делилась на количество соавторов) и Институт экономики УрО РАН (8,70). Организации находились в 18 городах, а больше всего статей опубликовали авторы из Нижнего Новгорода (24,84), Екатеринбурга (9,20) и Уфы (6,40). По второму массиву зафиксирована другая статистика [22]. Наличие в анализируемых публикациях разного количества регионов обусловило необходимость разделения массивов на три корпуса статей – RU (все регионы России), FD (регионы одного федерального округа, иногда двух-трех округов) и SR (выборка регионов). Получилось следующее распределение: в массиве с применением SOM доминировал корпус RU (57 статей и 122 результата) над FD (6 и 6) и SR (2 и 2), а в массиве традиционного кластерного анализа [Блануца, 2024] не было столь выраженного преобладания RU (414 и 515) над FD (144 и 187) и SR (46 и 79). В анализируемых публикациях с помощью нейросетевых и традиционных методов кластеризации предпринимались попытки определить уровни социально-экономического развития, инновационной деятельности, конкурентоспособности, экономической безопасности и социального неравенства для групп отечественных регионов.




Рис. 1. Изменение ежегодного количества статей по социально-экономической кластеризации регионов России с использованием самоорганизующихся карт Кохонена (А) и традиционного кластерного анализа (Б)

Fig. 1. Change in the annual number of articles on socio-economic clustering of Russian regions using Kohonen self-organizing maps (A) and traditional cluster analysis (B)

Источник: часть «А» составлена по публикациям в научных журналах в 2003–2023 гг., а часть «Б» заимствована из [Блануца, 2024].

Результаты и их обсуждение

При социально-экономической кластеризации регионов посредством алгоритма SOM не должна возникать дискриминация граждан Российской Федерации, проживающих в тех или иных субъектах. Однако обобщение выявленных статей из первого массива и сравнение со вторым массивом показало, что существует, как минимум, три направления пространственной алгоритмической предвзятости, с некоторой условностью названные «региональной сегрегацией», «кластерным сжатием» и «диапазонным смещением». Скорее всего, таких направлений гораздо больше, но для начала изучения SOM-обусловленной дискриминации отечественных регионов ограничимся первичным анализом только трех направлений.

Региональная сегрегация. Принудительное разделение регионов и проживающих в них граждан, произошедшее при реализации алгоритма SOM, на две группы – включенные в кластеризацию и исключенные из нее – может привести к репутационным, финансовым и иным потерям для исключенных регионов. В такой ситуации возможен эффект «сенсорной пустыни» [Robinson, Franklin, 2020], когда отсутствие сведений по некоторой территории не позволяет обосновать выделение средств на развитие данной территории. Это весьма чувствительно для дотационных регионов, но и для регионов-лидеров невключение в



кластеризацию может негативно повлиять на имидж. Также следует отметить, что изъятие любого региона нарушает целостность изучаемого экономического пространства – страны или федерального округа – и приводит к кластеризации, не соответствующей действительности. Обобщение выявленных статей позволило установить четыре причины удаления региона – «второстепенность» субъекта (относится к трем автономным округам, входящим в Тюменскую и Архангельскую области), отсутствие данных, аномальные значения имеющихся данных («выбросы») и неправильные априорные представления исследователей о кластерах (например, устранение кластеров, содержащих один регион).

В корпусе RU обнаружено 20 дискриминируемых регионов¹, среди которых более одного раза исключались из нейросетевых кластерных решений Ненецкий автономный округ (19 статей из 57 публикаций данного корпуса), Ханты-Мансийский автономный округ – Югра (15 статей), Ямало-Ненецкий автономный округ (15), Республика Крым (9), г. Севастополь (9), Чеченская Республика (6), Республика Ингушетия (2) и Республика Тыва (2). По одному разу удалялись Республика Адыгея, Республика Алтай, Архангельская область, Республика Дагестан, Кабардино-Балкарская Республика, Республика Калмыкия, Карачаево-Черкесская Республика, г. Москва, г. Санкт-Петербург, Республика Северная Осетия – Алания, Тюменская область и Чукотский автономный округ. В корпусе FD зафиксировано удаление двух регионов – г. Москва (3 статьи из 3 публикаций по Центральному федеральному округу) и Московская область (1). По корпусу SR не было исключенных регионов.

Кластерное сжатие. Определение количества кластеров является одной из наиболее проблемных операций SOM [Khanchouch et al., 2015]. Для нее в кластерном анализе нет единственно правильного решения. Если проводить анализ в программной среде R, то существует 30 индексов для определения числа кластеров [Charrad et al., 2014]. Однако в большинстве публикаций по нейросетевой кластеризации российских регионов отсутствует обоснование числа кластеров. Создается впечатление, что эта операция выполняется исследователями исходя из каких-то априорных субъективных суждений. В качестве иллюстрации приведем несколько примеров обоснования числа кластеров: «Нейросетевое моделирование показало, что регионы РФ распределились по четырем кластерам» [Перова, Папко, 2019, с. 25]; «В результате расчетов было выявлено 4 группы регионов (кластеров)» [Игнатьева и др., 2015, с. 100]; «В ходе вычислительных экспериментов все субъекты РФ в зависимости от уровня (очень низкий, низкий, ниже среднего, средний и выше среднего) социально-экономического развития были разбиты на 5 кластеров» [Гагарина и др., 2017, с. 1087]; «Исходя из результатов ретроспективной оценки инновационного развития российских регионов, было принято решение разбить их на пять кластеров» [Чередниченко и др., 2020, с. 332]; «Количество кластеров равно 5. Число кластеров задается исследователем исходя из целей анализа» [Трифонов и др., 2021, с. 41].

В статьях корпуса RU по нейросетевой кластеризации выделялось от 3 до 9 кластеров, но больше всего (73,8 %) было 4- и 5-кластерных решений (рис. 2, А). В публикациях соответствующего корпуса по традиционной кластеризации удельный вес результатов с четырьмя и пятью кластерами был значительно ниже (42,1 %), а разброс количества кластеров (от 2 до 18) – существенно больше (рис. 2, Б). Поскольку оба массива объединяет кластеризация одних и тех же регионов за одинаковый период времени и по имеющимся статистическим данным, то расхождение в числе кластеров с некоторой условностью можно отнести к специфике применяемых алгоритмов. Если исходить из того, что алгоритмы традиционной кластеризации получили гораздо большее применение и более понятны, то на этой основе можно оценить особенности «черного ящика» SOM. Главной

¹ При определении дискриминируемых территорий учитывались только современные регионы (на 1 января 2022 г. в Российской Федерации было 85 субъектов). Поэтому Усть-Ордынский Бурятский автономный округ и другие упраздненные субъекты не рассматривались. Республика Крым и г. Севастополь учитывались с 2015 г., так как по ним социально-экономическая статистика за 2014 г. была неполной.

особенностью SOM (см. рис. 2, А относительно рис. 2, Б) является кластерное сжатие, когда множество регионов делится на относительно небольшое (в сопоставлении с традиционной кластеризацией) число кластеров. При этом вызывает удивление отсутствие в RU 2-кластерных решений в условиях сильно поляризованного экономического пространства России (только в другом корпусе – FD – зафиксированы два таких решения для Центрального федерального округа). Одно из возможных объяснений отсутствия двух кластеров – наличие в некоторых программных продуктах настройки числа кластеров не менее трех.

Большинство социально-экономических кластерных решений предусматривают ранжирование выделенных групп регионов. Поскольку особое значение имеет попадание региона в число лидеров или аутсайдеров, то целесообразно свести все группы в три кластера – «верхний» (наилучшая ситуация), «средний» (промежуточные ситуации) и «нижний» (наихудшая ситуация). Тогда, например, при делении на 4 группы получится верхний, два средних и нижний кластеры, а при делении на 8 групп – верхний, шесть средних и нижний кластеры. Из такого расклада следует, что нижний кластер из четырех групп может объединить нижний и несколько (или один) средних кластеров из восьми групп. Таким образом, алгоритмическая предвзятость в виде кластерного сжатия проявляется в виде увеличения размера нижнего кластера. Аналогичное увеличение возможно и для верхнего кластера, но оно менее вероятно при использовании евклидова расстояния с его проблемами измерения максимальных значений показателей в сферических кластерах [Hadi, 2022].




Рис. 2. Количество результатов социально-экономической кластеризации всех российских регионов с разным числом кластеров, полученных на основе самоорганизующихся карт Кохонена (А) и традиционного кластерного анализа (Б)

Fig. 2. The number of socio-economic clustering results for all Russian regions with different numbers of clusters, obtained on the basis of Kohonen self-organizing maps (A) and traditional cluster analysis (B)

Источник: часть «А» составлена автором, а часть «Б» заимствована из [Блануца, 2024].

Не зная правильного кластерного решения, трудно определить российские регионы, несправедливо отнесенные с помощью SOM в кластер с самым низким уровнем социально-



экономического развития. Однако, опираясь на результаты традиционного кластерного анализа, можно выявить регионы с повышенной частотой попадания в нижний кластер. В корпусе RU (массив традиционных решений [Блануца, 2024]) при расчете уровня развития по данным за 2018–2022 гг. чаще других в нижний кластер входили республики Калмыкия (частота 0,93), Кабардино-Балкарская (0,86), Карачаево-Черкесская (0,86), Северная Осетия – Алания (0,86), Ингушетия (0,85), Дагестан (0,79), Тыва (0,72) и Чеченская (0,71), Еврейская автономная область (0,71), республики Крым (0,69) и Алтай (0,64), г. Севастополь (0,58), Забайкальский край (0,57) и Псковская область (0,57). В качестве примера сравним эти 14 регионов с кластером низких значений показателей инновационного развития в 2018 г. [50]: кроме 12 регионов из приведенного выше перечня (исключение составили Забайкальский край и Псковская область) в худший кластер включены еще 21 субъект (республики Бурятия и Коми, Алтайский и Камчатский край, Амурская, Астраханская, Брянская, Волгоградская, Иркутская, Калининградская, Кемеровская (Кузбасс), Костромская, Курганская, Магаданская, Мурманская, Новгородская и Орловская области, Ненецкий, Ханты-Мансийский (Югра), Чукотский и Ямало-Ненецкий автономные округа). Можно предположить, что в рассмотренной кластеризации из-за неправильного определения числа кластеров получился 21 дискриминируемый регион. Если выделять не четыре кластера, а больше, то 33 региона могли разделиться на несколько однородных групп, что приблизило бы кластерное решение к действительности.

Диапазонное смещение. Одной из характеристик кластерного решения является количество регионов в выделенных группах, зависящее от числа кластеров. Рассмотрим две наиболее распространенные ситуации в корпусе RU – четыре и пять кластеров (см. рис. 2, А). Для сравнения результатов нейросетевой кластеризации с результатами традиционного кластерного анализа целесообразно оперировать частотой встречаемости кластера с определенным количеством регионов в корпусах RU соответствующих массивов. Например, при 4-кластерном решении на основе SOM зафиксировано 3 кластера с одним регионом среди 144 кластеров, что соответствует частоте 0,0208, а при традиционной кластеризации – 11 кластеров с одним регионом, что при 244 кластерах соответствует частоте 0,0451. Для исключения флуктуаций кластеров с разным числом регионов будем использовать накопленную частоту встречаемости, то есть при 4 кластерах, выделенных на основе SOM, после встречаемости кластеров с одним регионом будет следовать встречаемость кластеров с 1–2 регионами (0,0555), затем с 1–3 регионами (0,0833) и т. д. (аналогичные расчеты выполнялись по результатам традиционной кластеризации). При таких ограничениях исходная гипотеза заключается в том, что при кластеризации одних и тех же регионов в пределах одного периода времени и по единой статистической базе, но с применением разных алгоритмов, должно наблюдаться примерное совпадение значений накопленной частоты встречаемости (сходимость графиков) для сравниваемых алгоритмов. Если оцениваемый алгоритм (SOM) иначе обрабатывает исходные данные, то происходит сдвиг его графика относительно графика традиционной кластеризации. При продолжительном сохранении сдвига (возьмем заведомо большую величину – не менее пятой части графика) в постоянно увеличивающемся диапазоне числа регионов в кластере можно идентифицировать алгоритмическую предвзятость в виде диапазонного смещения (альтернативная гипотеза). В этом случае интерпретация будет зависеть от местоположения смещения на графике.

Для 4-кластерных решений в корпусе RU наблюдается продолжительное ($18:77=0,23$) смещение значений для SOM в диапазоне от 1 до 18 регионов в кластере (рис. 3, А). При этом максимальный сдвиг ($0,2911-0,1874=0,1037$) пришелся на кластеры с 1–8 регионами. Более продолжительное смещение для SOM ($28:77=0,36$) зафиксировано в 5-кластерных решениях в отношении диапазона от 2 до 29 регионов в кластере (рис. 3, Б) с максимальным сдвигом ($0,5617-0,4295=0,1322$) в кластерах с 2–11 регионами. Приведенные значения подтверждают альтернативную гипотезу, то есть имеет место алгоритмическая

предвзятость. Поскольку диапазонные смещения при выделении четырех и пяти кластеров с помощью SOM пришлось на группы с небольшим количеством регионов, то можно констатировать предвзятое стремление нейросетевого алгоритма формировать как можно более крупные (по количеству регионов) кластеры. Например, в корпусе RU при выделении 5 кластеров с помощью SOM максимальный размер одного кластера составил 68 регионов (частота встречаемости 0,0074), а при традиционной кластеризации – 63 региона (0,0024).




Рис. 3. Частота встречаемости кластеров при увеличении их максимального размера (количества регионов) в результате объединения всех субъектов Российской Федерации в четыре (А) и пять (Б) кластеров на основе обработки социально-экономических данных с помощью самоорганизующихся карт Кохонена (1) и традиционного кластерного анализа (2)

Fig. 3. Frequency of occurrence of clusters with an increase in their maximum size (number of regions) as a results of combining all regions of the Russian Federation into four (A) and five (B) clusters based on the processing of socio-economic data using Kohonen self-organizing maps (1) and traditional cluster analysis (2)

Источник: составлено автором.

В этом виде алгоритмической предвзятости дискриминируемые регионы появляются при чрезмерном (относительно традиционной кластеризации) нейросетевом увеличении размера кластера. Если оперировать средним размером нижнего кластера в корпусе RU, то при использовании SOM он составляет 29 регионов, а в традиционных кластерных решениях – 18 регионов. При разнообразии количества кластеров приведенные средние значения не совсем корректны, но в некоторой мере отражают увеличение размера нижнего кластера в SOM-решениях (к примеру, при четырех кластерах получается, соответственно, 27 и 15 регионов). С этих позиций в уже приводимом примере кластера низких значений показателей инновационного развития в 2018 г. [Летягина, Перова, 2021] из 33 регионов



могут оказаться неправильно включенными в кластер (дискриминируемыми) 18 субъектов (при четырех кластерах получается $33-15=18$; что касается кластерного сжатия, то там идентифицирован 21 регион). Еще один пример – оценка социально-экономического развития российских регионов в 2007–2011 гг. [Серкова и др., 2014]: в четвертый кластер («депрессивные регионы») вошел 31 субъект, из которых 16 ($31-15=16$) могут оказаться дискриминируемыми. Допустим, 14 регионов нижнего кластера¹, выделенные по традиционным решениям на основе данных за 2018–2022 гг., имели такой же статус и в 2007–2011 гг. Тогда 16 дискриминируемых регионов могут находиться среди следующих 20 субъектов ($31-14+3=20$): республики Бурятия, Марий Эл, Мордовия, Удмуртская, Хакасия и Чувашская, Алтайский и Ставропольский край, Амурская, Брянская, Владимирская, Вологодская, Ивановская, Кировская, Костромская, Курганская, Орловская, Пензенская, Тверская и Ульяновская области.

Заключение

Анализ литературы по искусственному интеллекту, традиционной и нейросетевой кластеризации позволил определить несколько чувствительных областей в самоорганизующихся картах Кохонена, способных генерировать пространственную алгоритмическую предвзятость. Сопоставление этих областей с отечественным опытом социально-экономической группировки регионов с помощью SOM и традиционного кластерного анализа привело к обнаружению трех видов алгоритмической предвзятости, дискриминирующих отдельные российские регионы. Результатом региональной сегрегации является реальная дискриминация (среди 85 субъектов Российской Федерации обнаружено 20 регионов, в разной мере исключаемых из процесса кластеризации), а следствием кластерного сжатия и диапазонного смещения – потенциальная дискриминация, связанная с неправомерным отнесением регионов к кластеру самого низкого уровня социально-экономического развития. При одновременном максимальном проявлении трех видов предвзятости может сложиться ситуация с исключением всех специфических регионов («выбросов») и разбиением оставшихся субъектов на как можно меньшее число кластеров одинаково большого размера, что станет крайней формой искажения существующего социально-экономического разнообразия российских регионов.

Дальнейшие исследования по обозначенной проблематике могут проводиться в пяти наиболее перспективных направлениях. Во-первых, предстоит разработать способ экономической оценки прямых и косвенных потерь региона в результате предвзятой кластеризации. Во-вторых, выявление трех видов алгоритмической предвзятости SOM является лишь первым шагом в осмыслении несправедливости нейросетевой кластеризации, после чего необходимо изучить другие чувствительные параметры (например, радиус обучения и функция соседства) в отношении реальной или потенциальной дискриминации регионов. В-третьих, наметившийся переход к использованию «больших данных» в региональных исследованиях заставит приспособливать SOM к обработке непрерывного потока разнообразных данных. Известно, что использование «больших данных» приводит к дискриминации [Favaretto, De Clercq, 2019], но как это проявится при обработке таких данных с помощью SOM, еще предстоит выяснить. В-четвертых, необходимость экономической экспертизы федеральных проектов и стратегий заставит применять кластерный анализ. К примеру, это сделано в отношении обоснованности достижения регионами национальных целей развития [Блануца, 2022]. Нейросетевая кластеризация для экспертизы еще не применялась, но, предвосхищая будущее использование SOM, предстоит выяснить непредвзятость алгоритма при анализе стратегических документов. В-пятых, выявление алгоритмической предвзятости необходимо для разработки механизма справедливой кластеризации. В этом направлении много сделано, но не применительно к регионам и тем

¹ Кроме Республики Крым и г. Севастополь, которые до 2014 г. не входили в состав Российской Федерации, а также Республики Северная Осетия – Алания, не попавшей в кластер депрессивных регионов.

более их функционированию в едином экономическом пространстве России. Потребуется разработать такой алгоритм нейросетевой кластеризации, который исключит какую-либо дискриминацию любого российского региона.

Список литературы

- Блануца В.И. 2020. Региональные экономические исследования с использованием алгоритмов искусственного интеллекта: состояние и перспективы. *Вестник Забайкальского государственного университета*, 26 (8): 100–111.
- Блануца В.И. 2022. Кластеризация регионов Сибири и Дальнего Востока по достижению национальных целей развития. *Российский экономический журнал*, 3: 63–83.
- Блануца В.И. 2024. Пространственная алгоритмическая предвзятость в социально-экономической кластеризации российских регионов. *Пространственная экономика*, 20 (2): 71–92.
- Гагарина Г.Ю., Дзюба Е.И., Губарев Р.В., Файзуллин Ф.С. 2017. Прогнозирование социально-экономического развития российских регионов. *Экономика региона*, 13 (4): 1080–1094.
- Игнатьева А.Е., Серкова Е.Д., Мариев О.С. 2015. Сравнительные преимущества российских регионов в развитии и размещении производительных сил. *Вестник Челябинского государственного университета*, 18: 98–104.
- Летягина Е.Н., Перова В.И. 2021. Нейросетевое моделирование региональных инновационных экосистем. *Journal of New Economy*, 22 (1): 71–89.
- Перова В.И., Папко А.В. 2019. Нейросетевой анализ динамики инвестиционной деятельности регионов Российской Федерации. *Вестник Нижегородского университета им. Н.И. Лобачевского. Серия: Социальные науки*, 1: 24–32.
- Серкова А.Е., Игнатьева Е.Д., Мариев О.С. 2014. Оценка социально-экономического развития российских регионов-субъектов Российской Федерации. *Вестник Челябинского государственного университета*, 21: 112–120.
- Трифонов Ю.В., Сочков А.Л., Соловьёв А.Е. 2021. Оценка экономического потенциала регионов РФ на основе методологии нейросетевого кластерного анализа. *Вестник Нижегородского университета им. Н.И. Лобачевского. Серия: Социальные науки*, 3: 38–47.
- Чередниченко Л.Г., Губарев Р.В., Дзюба Е.И., Файзуллин Ф.С. 2020. Целевое управление инновационным развитием России. *Вестник СПбГУ. Экономика*, 36 (2): 319–350.
- Agarwal P., Skupin A. (Eds.) 2008. *Self-Organising Maps: Applications in Geographic Information Science*. Chichester; Hoboken: Wiley, 214 p.
- Carboni O., Russu P. 2015. Assessing regional wellbeing in Italy: An application of Malmquist DEA and self-organizing map neural clustering. *Social Indicators Research*, 122 (3): 677–700.
- Chabra A., Masalkovaitė K., Mohapatra P. 2021. An overview of fairness in clustering. *IEEE Access*, 9: 130698–130720.
- Charrad M., Ghazzali N., Boiteau V., Niknafs A. 2014. NbClust: An R package for determining the relevant number of clusters in a data set. *Journal of Statistical Software*, 61 (6): 1–36.
- Favaretto M., De Clercq B.S. 2019. Big data and discrimination: Perils, promises and solutions. A systematic review. *Journal of Big Data*, 6 (1): 12–27.
- Giordani P., Ferraro M.B., Martella F. 2020. *An Introduction to Clustering with R*. Singapore: Springer, 340 p.
- Gupta S., Ghalme G., Krishnan N.C., Jain S. 2023. Efficient algorithms for fair clustering with a new notion of fairness. *Data Mining and Knowledge Discovery*, 37: 1959–1997.
- Hadi A.S. 2022. A new distance between multivariate clusters of varying locations, elliptical shapes, and directions. *Pattern Recognition*, 129: 108780.
- Jackson M.C. 2021. Artificial intelligence and algorithmic bias: The issues with technology reflecting history and humans. *Journal of Business and Technology Law*, 16 (2): 299–316.
- Khanchouch I., Charrad M., Limam M. 2015. A comparative study of multi-SOM algorithms for determining the optimal number of clusters. *International Journal of Future Computer and Communication*, 4 (3): 198–202.
- Khasanah A.U. 2016. A comparison study: Clustering using self-organizing map and k-means algorithm. *Performa*, 15 (1): 51–58.
- Kohonen T. 1982. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43: 59–69.



- Kohonen T. 2001. Self-Organizing Maps. Third Edition. Berlin; Heidelberg: Springer, 502 p.
- Kordzadeh N., Ghasemaghaei M. 2022. Algorithmic bias: Review, synthesis, and future research directions. *European Journal of Information Systems*, 31 (3): 388–409.
- Kourtit K., Arribas-Bel D., Nijkamp P. 2012. High performance in complex spatial systems: A self-organizing mapping approach with reference to The Netherlands. *The Annals of Regional Science*, 48: 501–527.
- Lypez-Villuendas A.M., del Campo C. 2023. Regional economic disparities in Europe: Time-series clustering of NUTS 3 regions. *International Regional Science Review*, 46 (3): 265–298.
- Lorimer T., Held J., Stoop R. 2017. Clustering: How much bias do we need? *Philosophical Transactions of the Royal Society A*, 375: 20160293.
- Mirkin B. 1996. Mathematical Classification and Clustering. Dordrecht; Boston; London: Kluwer Academic Publisher, 429 p.
- Nishant R., Schneckenberg D., Ravishankar M. The formal rationality of artificial intelligence-based algorithms and the problem of bias. *Journal of Information Technology*, 39 (1): 19–40.
- Robinson C., Franklin R.S. 2020. The sensor desert quandary: What does it mean (not) to count in the smart city? *Transactions of the Institute of British Geographers*, 46 (2): 238–254.
- Ros F., Riad R., Guillaume S. 2024. Deep clustering framework review using multicriteria evaluation. *Knowledge-Based Systems*, 285: 111315.
- Schmidt C.R., Rey S.J., Skupin A. 2011. Effects of irregular topology in spherical self-organizing maps. *International Regional Science Review*, 34 (2): 215–229.
- Soares J.O., Coutinho C.C. 2010. Cluster analysis in regional science. *Advances and Applications in Statistical Science*, 1 (2): 311–325.
- Van Giffen B., Herhausen D., Fahse T. 2022. Overcoming the pitfalls and perils of algorithms: A classification of machine learning biases and mitigation methods. *Journal of Business Research*, 144: 93–106.
- Wei X., Zhang Z., Huang H., Zhou Y. 2024. An overview on deep clustering. *Neurocomputing*, 590: 127761.
- Yin H. 2008. The self-organizing maps: Background, theories, extensions and applications. In: Fulcher J., Jain L.C. (Eds.). *Computational Intelligence: A Compendium*. Berlin: Springer, 715–762.

References

- Blanutsa V.I. 2020. Regional economic research using artificial intelligence algorithms: state and prospects. *Bulletin of Zabaikalsky State University*, 26 (8): 100–111 (in Russian).
- Blanutsa V.I. 2022. Clustering the regions of Siberia and the Far East to achieve national development goals. *Russian Economic Journal*, 3: 63–83 (in Russian).
- Blanutsa V.I. 2024. Spatial algorithmic bias in socio-economic clustering of Russian regions. *Spatial Economics*, 20 (2): 71–92 (in Russian).
- Gagarina G.Yu., Dzyuba E.I., Gubarev R.V., Fayzullin F.S. 2017. Forecasting the socio-economic development of Russian regions. *Economics of the Region*, 13 (4): 1080–1094 (in Russian).
- Ignatieva A.E., Serkova E.D., Mariev O.S. 2015. Comparative advantages of Russian regions in the development and location of productive forces. *Bulletin of the Chelyabinsk State University*, 18: 98–104 (in Russian).
- Letyagina E.N., Perova V.I. 2021. Neural network modeling of regional innovation ecosystems. *Journal of New Economy*, 22 (1): 71–89 (in Russian).
- Perova V.I., Papko A.V. 2019. Neural network analysis of the dynamics of investment activity in the regions of the Russian Federation. *Bulletin of the Nizhny Novgorod Lobachevsky University. Series: Social Sciences*, 1: 24–32 (in Russian).
- Serkova A.E., Ignatieva E.D., Mariev O.S. 2014. Assessment of socio-economic development of Russian regions-subjects of the Russian Federation. *Bulletin of the Chelyabinsk State University*, 21: 112–120 (in Russian).
- Trifonov Yu.V., Sochkov A.L., Solovyov A.E. 2021. Assessment of the economic potential for the Russian Federation's regions based on the methodology of neural network cluster analysis. *Bulletin of the Nizhny Novgorod Lobachevsky University. Series: Social Sciences*, 3: 38–47 (in Russian).
- Cherednichenko L.G., Gubarev R.V., Dzyuba E.I., Fayzullin F.S. 2020. Targeted management of Russia's innovative development. *Bulletin of St. Petersburg State University. Economics*, 36 (2): 319–350 (in Russian).

- Agarwal P., Skupin A. (Eds.) 2008. *Self-Organising Maps: Applications in Geographic Information Science*. Chichester; Hoboken: Wiley, 214 p.
- Carboni O., Russu P. 2015. Assessing regional wellbeing in Italy: An application of Malmquist DEA and self-organizing map neural clustering. *Social Indicators Research*, 122 (3): 677–700.
- Chabra A., Masalkovaitė K., Mohapatra P. 2021. An overview of fairness in clustering. *IEEE Access*, 9: 130698–130720.
- Charrad M., Ghazzali N., Boiteau V., Niknafs A. 2014. NbClust: An R package for determining the relevant number of clusters in a data set. *Journal of Statistical Software*, 61 (6): 1–36.
- Favaretto M., De Clercq B.S. 2019. Big data and discrimination: Perils, promises and solutions. A systematic review. *Journal of Big Data*, 6 (1): 12–27.
- Giordani P., Ferraro M.B., Martella F. 2020. *An Introduction to Clustering with R*. Singapore: Springer, 340 p.
- Gupta S., Ghalme G., Krishnan N.C., Jain S. 2023. Efficient algorithms for fair clustering with a new notion of fairness. *Data Mining and Knowledge Discovery*, 37: 1959–1997.
- Hadi A.S. 2022. A new distance between multivariate clusters of varying locations, elliptical shapes, and directions. *Pattern Recognition*, 129: 108780.
- Jackson M.C. 2021. Artificial intelligence and algorithmic bias: The issues with technology reflecting history and humans. *Journal of Business and Technology Law*, 16 (2): 299–316.
- Khanchouch I., Charrad M., Limam M. 2015. A comparative study of multi-SOM algorithms for determining the optimal number of clusters. *International Journal of Future Computer and Communication*, 4 (3): 198–202.
- Khasanah A.U. 2016. A comparison study: Clustering using self-organizing map and k-means algorithm. *Performa*, 15 (1): 51–58.
- Kohonen T. 1982. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43: 59–69.
- Kohonen T. 2001. *Self-Organizing Maps*. Third Edition. Berlin; Heidelberg: Springer, 502 p.
- Kordzadeh N., Ghasemaghaei M. 2022. Algorithmic bias: Review, synthesis, and future research directions. *European Journal of Information Systems*, 31 (3): 388–409.
- Kourtit K., Arribas-Bel D., Nijkamp P. 2012. High performance in complex spatial systems: A self-organizing mapping approach with reference to The Netherlands. *The Annals of Regional Science*, 48: 501–527.
- Lopez-Villuendas A.M., del Campo C. 2023. Regional economic disparities in Europe: Time-series clustering of NUTS 3 regions. *International Regional Science Review*, 46 (3): 265–298.
- Lorimer T., Held J., Stoop R. 2017. Clustering: How much bias do we need? *Philosophical Transactions of the Royal Society A*, 375: 20160293.
- Mirkin B. 1996. *Mathematical Classification and Clustering*. Dordrecht; Boston; London: Kluwer Academic Publisher, 429 p.
- Nishant R., Schneckenberg D., Ravishankar M. The formal rationality of artificial intelligence-based algorithms and the problem of bias. *Journal of Information Technology*, 39 (1): 19–40.
- Robinson C., Franklin R.S. 2020. The sensor desert quandary: What does it mean (not) to count in the smart city? *Transactions of the Institute of British Geographers*, 46 (2): 238–254.
- Ros F., Riad R., Guillaume S. 2024. Deep clustering framework review using multicriteria evaluation. *Knowledge-Based Systems*, 285: 111315.
- Schmidt C.R., Rey S.J., Skupin A. 2011. Effects of irregular topology in spherical self-organizing maps. *International Regional Science Review*, 34 (2): 215–229.
- Soares J.O., Coutinho C.C. 2010. Cluster analysis in regional science. *Advances and Applications in Statistical Science*, 1 (2): 311–325.
- Van Giffen B., Herhausen D., Fahse T. 2022. Overcoming the pitfalls and perils of algorithms: A classification of machine learning biases and mitigation methods. *Journal of Business Research*, 144: 93–106.
- Wei X., Zhang Z., Huang H., Zhou Y. 2024. An overview on deep clustering. *Neurocomputing*, 590: 127761.
- Yin H. 2008. The self-organizing maps: Background, theories, extensions and applications. In: Fulcher J., Jain L.C. (Eds.). *Computational Intelligence: A Compendium*. Berlin: Springer, 715–762.



Конфликт интересов: о потенциальном конфликте интересов не сообщалось.
Conflict of interest: no potential conflict of interest related to this article was reported.

Поступила в редакцию 27.02.2025
Поступила после рецензирования 07.03.2025
Принята к публикации 10.03.2025

Received February 27, 2025
Revised March 07, 2025
Accepted March 10, 2025

ИНФОРМАЦИЯ ОБ АВТОРЕ

Блануца Виктор Иванович, доктор географических наук, эксперт РАН по экономическим наукам, ведущий научный сотрудник, Институт географии имени В.Б. Сочавы Сибирского отделения Российской академии наук, г. Иркутск, Россия

INFORMATION ABOUT THE AUTHOR

Viktor I. Blanutsa, Doctor of Geographical Sciences, RAS expert in Economic Sciences, Leading Researcher, V.B. Sochava Institute of Geography of the Siberian Branch of the Russian Academy of Sciences, Irkutsk, Russia