

Алгоритм построения прогнозной модели транспортно-логистической деятельности на основе применения нечетких нейронных сетей

В. А. Ламехов, Е. К. Коровяковский

Петербургский государственный университет путей сообщения Императора Александра I, Российская Федерация, 190031, Санкт-Петербург, Московский пр., 9

Для цитирования: Ламехов В. А., Коровяковский Е. К. Алгоритм построения прогнозной модели транспортно-логистической деятельности на основе применения нечетких нейронных сетей // Бюллетень результатов научных исследований. — 2022. — Вып. 3. — С. 137–150. DOI: 10.20295/2223-9987-2022-3-137-150

Аннотация

Цель: Рассмотреть существующую ситуацию на рынке контейнерных перевозок Ленинградской области. Показать необходимость построения новых прогностических моделей. Обосновать применение нейронных нечетких сетей. Рассмотреть существующие ограничения их применения. Предложить способы построения прогностических нейронных нечетких моделей для оценки перспективных количественных показателей логистической деятельности. **Методы:** ANFIS, R-ANFIS, Fuzzy-Partitions, SCRG, GD, LSE, PSO, ABC, FA. **Результаты:** Указана необходимость адаптации нейронных нечетких сетей для проведения прогнозов в области логистики, предложена структура перспективной модели, учитывающей использование и анализ множества методов структурной и параметрической идентификации. Указаны недостатки отдельных методов структурной и параметрической идентификации, влияющие на точность получаемых прогнозов. **Практическая значимость:** Показана значимость построения точных прогностических моделей для ключевых количественных показателей логистической деятельности. Приведены факторы, влияющие на осуществление транспортно-логистической деятельности, достоверный прогноз которых в ситуациях ограниченного времени и ресурсов невозможен. В статье предложены к рассмотрению существующие методы параметрической и структурной идентификации нечетких нейронных сетей. Предложен алгоритм адаптации существующих методов для использования в транспортно-логистическом процессе.

Ключевые слова: Нечеткие нейронные сети, гибридные нейронные сети, методы параметрической и структурной идентификации, методы обучения, контейнерный терминал, логистика, прогнозирование.

Введение

В соответствии с Транспортной стратегией 2030 [1] основным направлением международной интеграции России является создание интеграция российской и европейской транспортных систем. В настоящее время наблюдается существенное увеличение объемов экспортно-импортных грузопотоков как в пределах Ленинградской области, так и по всей территории России. Благодаря конкурентным преимуществам, связанным с уникальным для России географическим положением на побережье Балтийского моря, возможности удобного выхода на основные торговые пути Северной Европы, развитой транспортной инфраструктуре

и налаженным связям с регионами России и со странами Европейского союза, транспортная система Санкт-Петербурга и Ленинградской области обеспечивает 25 % от общего объема перевозок внешнеторговых грузов России. Морские порты Ленинградской области обеспечивают более 50 % от общего объема контейнерных грузов, переваливаемых в портах России [2]. Наблюдается наличие существенных запасов перерабатывающих мощностей контейнерных терминалов северо-запада России, превосходящих потребную перерабатывающую способность в 2,5–3 раза.

Соотношение объемов перевалки контейнеров в тысячах ДФЭ в 2014–2021 гг. приведены в табл. 1. В табл. 2 представлены объем и динамика изменения контейнерооборота терминалов Ленинградской области.

ТАБЛИЦА 1. Анализ объемов перевалки контейнеров, тыс. ДФЭ

	2014	2015	2016	2017	2018	2019	2020	2021
Санкт-Петербург и ЛО	2 482	1 805	1 829	1 990	2 200	2 283	2150	2072
Всего по России	5 110	3 784	3 819	4 429	4 872	5 091	5049	5405

ТАБЛИЦА 2. Объем контейнерооборота терминалов ЛО, тыс. ДФЭ, %

Терминал	2014	+/- %	2015	+/- %	2016	+/- %	2017	+/- %	2018	+/- %	2019	+/- %	2020	+/- %	2021
ПЛП	658	-43	376	-30	265	-22	206	+19	246	+33	328	+15	377	+6	399
ПКТ	941	-39	578	-17	480	+15	554	+11	617	+6	654	0	654	-4	628
УЛКТ	104	-17	86	-5	82	-10	74	-7	69	-10	62	-19	50	-42	29
Моби Дик	228	-26	169	-8	155	+8	168	-51	82	-87	11	-	0	0	0
КТСП	388	-3	398	+40	558	+15	644	+12	722	+5	759	-13	659	+9	716
МПСПБ	0	0	0	+	3	+233	10	+50	15	+113	32	-3	31	-48	16
Бронка	0	+	91	+88	171	+27	218	+50	326	-3	317	-	-	-	-

В условиях стабильного роста перевалки контейнеров в портах и терминалах ЛО наблюдается перераспределение потока контейнерных грузов между терминалами на протяжении всего срока наблюдения. Планирование и разработка долгосрочных грузо- и вагонопотоков не всегда является эффективным методом управления имеющимися мощностями.

Характеристика рассматриваемой проблемы

Для решения данной задачи необходимо повышение эффективности информационной системы, с помощью которой осуществляется планирование транспортно-логистического процесса.

В настоящее время в условиях глобальной неопределенности практически невозможно обеспечить требуемое потребителями качество обслуживания, достоверное планирование и управление производственным процессом без применения сложных информационных систем сбора данных, анализа, планирования и поддержки принятия решений. В работах [3–5] рассматриваются проблемы и направления развития железнодорожных и мультимодальных перевозок в России, анализируются параметры, влияющие на устойчивое развитие транспортно-логистического бизнеса в России. Информационная вооруженность является важнейшим показателем успешности работы предприятия. За счет внедрения в деятельность крупных предприятий транспорта и коммерции компонентов IoT, Data Science появилась возможность детального сбора и анализа огромного количества данных, непосредственно влияющих на эффективность всего транспортно-логистического процесса. Важность доступности информации для организации перевозок рассмотрена в статье [6].

Несмотря на множество инструментов поддержки принятия решений, существуют такие параметры, которые невозможно оценить или достоверно предсказать, используя доступные средства и в разумные сроки. Так, почти на каждом этапе организации и перевозки грузов присутствуют параметры, оценка которых невозможна в перспективе: доступность транспортных средств на определенный период, стоимость и продолжительность перевозки. Некоторые из них могут быть точно оценены путем использования большого массива разрозненных данных и сложных прогностических механизмов, некоторые параметры зависят от множества макроэкономических факторов, поведение которых непредсказуемо на локальном уровне.

В табл. 3 проведен анализ возможности учета, анализа и оценки факторов, влияющих на транспортно-логистический процесс.

ТАБЛИЦА 3. Анализ возможности учета факторов, влияющих на транспортно-логистический процесс

Фактор или группа факторов	Возможность предсказания и оценки	Причина
Стоимость перевозки	+/-	Зависимость от множества макроэкономических показателей для различных видов транспорта в перспективе
Сроки перевозки	+/-	Комплексный показатель, зависящий от множества достоверно непредсказуемых факторов. Точность оценки варьируется для различных видов транспорта
Доступность транспортных средств	+/-	Отсутствие достоверных данных при планировании в долгосрочной перспективе
Спрос и предложение	+/-	Наличие множества инструментов прогноза, различающихся своей сложностью и достоверностью выходных данных

Рассмотри факторы, представленные в табл. 3. Неопределенность факторов выражена невозможностью описания или исчисления существующих в нем закономерностей, построения математической модели, вычисления зависимости между входными и выходными величинами, неполнотой данных о сущности рассматриваемого фактора. В условиях повышенной конкуренции, наблюдаемой, например, в сфере перевалки контейнерных грузов в Ленинградской области, велика вероятность построения средне- и долгосрочных позитивных прогнозов каждым поставщиком услуг, не учитывающих взаимное влияние на работу в рамках одного рынка. Негативное влияние подобной неопределенности выражается в создании избыточных мощностей.

Однако предполагается, что для каждого фактора существуют некоторые данные о значении его параметров, собранных в определенные моменты времени, соответственно, следует возможность применения методик, основанных на работе с временными рядами.

Для решения подобных задач на протяжении нескольких десятков лет применяются различные модели и методы, среди них — нечеткие модели.

Проблемы применения нейронных нечетких сетей для прогнозирования показателей железнодорожного транспорта

Нечеткими моделями называются модели статических и динамических систем, построение, анализ и применение которых базируется на положениях теории нечетких множеств, нечеткой логики и вывода, нечеткого анализа. Нечеткие модели представляют собой обобщение интервальных моделей. В 1992 г. Вангом было доказано, что нечеткая система может аппроксимировать любую непрерывную функцию с произвольной точностью, используя набор нечетких правил. Изначально сложность построения данных систем основывалась на эмпирическом подборе нечетких правил, их параметрической идентификации.

На данный момент гибридные интеллектуальные системы, основанные на комбинации нечетких и нейросетевых технологий, являются наиболее перспективным направлением развития задач, связанных с представлением и моделированием нелинейных процессов. В основе данных систем лежат достоинства нечетких моделей, в которых консеквенты извлекаются на основе аппарата нечеткой логики, а обучение производится с использованием классических градиентных алгоритмов. Разновидностью гибридных нечетких нейронных сетей является модель типа ANFIS, предложенная Янгом в 1993 г. [7]. Структура сети ANFIS представлена на рис. 1.

Сеть ANFIS основана на системе нечеткого вывода Такаги — Сугено. Данная сеть состоит из 5 слоев: первый слой представлен радиально-базисными

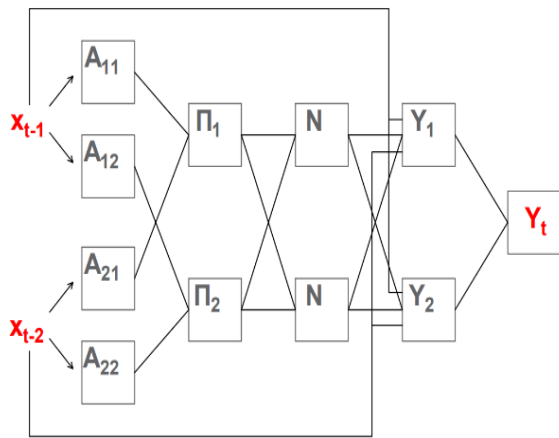


Рис. 1. Структура
продукционной модели типа
ANFIS

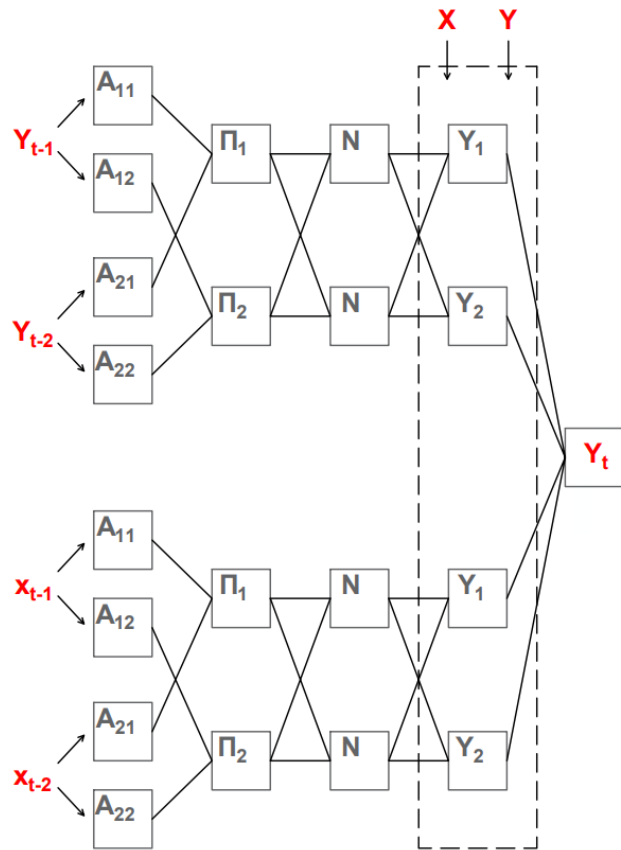


Рис. 2. Структура продукционной
модели типа R-ANFIS

нейронами и моделирует функции принадлежности (выполняет фуззификацию входных данных), на втором слое применяется оператор т-нормы, в нечеткой логике использующийся как оператор конъюнкции, третий слой необходим для нормализации полученных степеней принадлежности antecedента, на четвертом слое формируется значение консеквента, пятый слой необходим для дефузификации выходного значения.

Для прогнозирования нестационарных временных рядов в последнее время широкое распространение получили методы, основанные на использовании рекуррентных нечетких нейронных сетей. Данный метод был впервые предложен в работе Жанга и Морриса в 1999 г. [8]. Метод был распространен для использования с ANFIS-моделями и получил аббревиатуру R-ANFIS. В своей топологии данные рекуррентные ANFIS имеют обратные связи, за счет которых на вход модели подаются не только входные данные, но и выходные. В общем виде структура рекуррентной ANFIS сети представлена на рис. 2.

Сложность реализации данного подхода для задач, описанных в табл. 3, заключается в подборе количества нечетких правил «ЕСЛИ — ТО» и параметров их функций принадлежности. Эмпирическая оценка каждого фактора, приведенного в

табл. 3, занимает большое количество времени, так как связана с выделением термов лингвистических переменных для описания нечетких правил, экспертной оценкой каждого измерения показателя каждого фактора. Все вышеперечисленное приводит к тому, что использование системы требует существенного количества времени и наличия обученных специалистов. Соответственно, для оперативного применения системы требуется автоматизация построения системы нечетких правил.

Методы структурной и параметрической идентификации

Для структурной идентификации параметров нечеткой нейронной сети, т. е. количества нечетких правил «ЕСЛИ — ТО», и их предварительной оптимизации принято использовать методы, предложенные в работах [9–12].

Перечислим классические методы структурной идентификации нечетких нейронных сетей:

1. Лин, Каннингем и Кагешол в 1997 г. в работе [9] предложили метод, основанный на разбиении пространства исходных входных данных на контейнеры таким образом, чтобы *выходные* данные полученных контейнеров входных данных имели наибольшую абсолютную разность. Разбив пространство входных данных на некоторое количество контейнеров, вычисляется функция принадлежности нечеткого правила для каждого контейнера. Применение данного метода ограничивается сложностью поиска мест разбиения пространства входных данных на контейнеры.

2. Кастеллано, Финелли и Менкар в 2002 г. в работе [10] разработали подход, при котором на пространстве входных данных строятся степени принадлежности небольшого, заранее заданного количества нечетких правил таким образом, чтобы перекрывать все пространство входных данных. Полученные результаты применения метода могут быть легко интерпретированы человеком, однако недостаточная точность получаемых выходных данных и потребность в использовании специфической, нечеткой нейронной сети, предложенной авторами, не позволяют говорить об универсальности метода.

3. Наиболее удобный в использовании алгоритм получения нечетких правил был предложен Ли в 2003 г. в работе [11]. Он подразумевает разбиение входных и выходных данных на нечеткие кластеры. Данный метод наиболее распространен, однако подразумевает задание некоторых параметров эмпирическим путем, что влияет на количество получаемых нечетких правил и точность системы в целом.

Параметрическая идентификация, т. е. подбор параметров функций принадлежности нечетких правил (антецедентов) и параметров консеквентов, в рассмотренных работах осуществлялась комбинацией методов градиентного спуска (GD) и наименьших квадратов (LSE).

Существует проблема выбора методов параметрической идентификации для обучения моделей ANFIS и R-ANFIS. Классические методы обучения нейронных нечетких сетей, описанные выше, подвержены проблемам локального минимума ввиду обучения в два этапа, а также медленной сходимости метода градиентного спуска.

В работах [12–25] были предложены инновационные подходы к обучению нейронных нечетких сетей. Эти подходы основаны на множестве различных комбинаций методов оптимизации роя частиц (PSO) (и его разновидностей: квантово-управляемой и взвешенной оптимизации роя частиц), генетических алгоритмов (GA), метода искусственной пчелиной колонии (ABC), алгоритма светлячка (FA), метода расширенного фильтра Калмана.

В работах [12–15] используются PSO в сочетании с LSE для параметрической идентификации antecedентов и консеквентов соответственно. Данные методы были использованы для прогнозирования цен на электроэнергию, силы ветра, удовлетворенности покупателей новым продуктом, управления нелинейными системами.

В работах [16, 17] используется квантово-управляемая оптимизация роя частиц для идентификации параметров ANFIS. Эти системы применяются для прогнозирования тенденций валютного рынка.

В работах [18–20] используются генетические алгоритмы, а также генетические алгоритмы в сочетании с методом наименьших квадратов для прогнозирования временных рядов, значений широты и долготы, энергетической нагрузки.

В работе [21] используется R-ANFIS для моделирования многошагового прогноза наводнения. В качестве методов обучения данной модели использованы генетические алгоритмы и метод наименьших квадратов.

В работе [22] рассмотрен вариант предварительной обработки исходных данных путем кластеризации методом ближайших соседей, что позволило сократить время на обучение модели и увеличить точность прогнозов.

В работах [23–25] рассмотрены алгоритмы искусственной пчелиной колонии (ABC), роя кошек (CSO).

На данный момент не существует исследований применения методов нечеткого нейронного прогнозирования к проблемам прогнозирования временных рядов параметров, рассмотренных в табл. 3, в рамках транспортной логистики, однако данные методы широко используются для прогнозирования временных рядов в различных сферах. Однако нечеткие множества, аппарат нечеткой логики, нечеткие нейронные сети на железнодорожном транспорте используются для решения задач повышения устойчивости плана формирования [26], оптимизации формирования маршрутов перевозок [27], планирования грузовых перевозок [28].

Предлагаемый метод и его структура

Сложность переноса заключается в подборе такой комбинации алгоритмов структурной и параметрической идентификации, дополнительных методов предварительной обработки данных, а также самих моделей нечетких нейронных сетей, чтобы обеспечивалась достаточная точность прогнозируемых показателей совместно со скоростью предоставления таких прогнозов, позволяющих в режиме онлайн перебирать различные варианты организации транспортно-логистического процесса. Помимо этого, в зависимости от дальности прогноза варьируется точность различных методик.

Поэтому предполагается выстроить адаптивный алгоритм, способный подобрать оптимальный прогнозный механизм в зависимости от параметров исходных данных прогнозируемого показателя и дальности прогноза. Структурная схема данного алгоритма представлена на рис. 3.

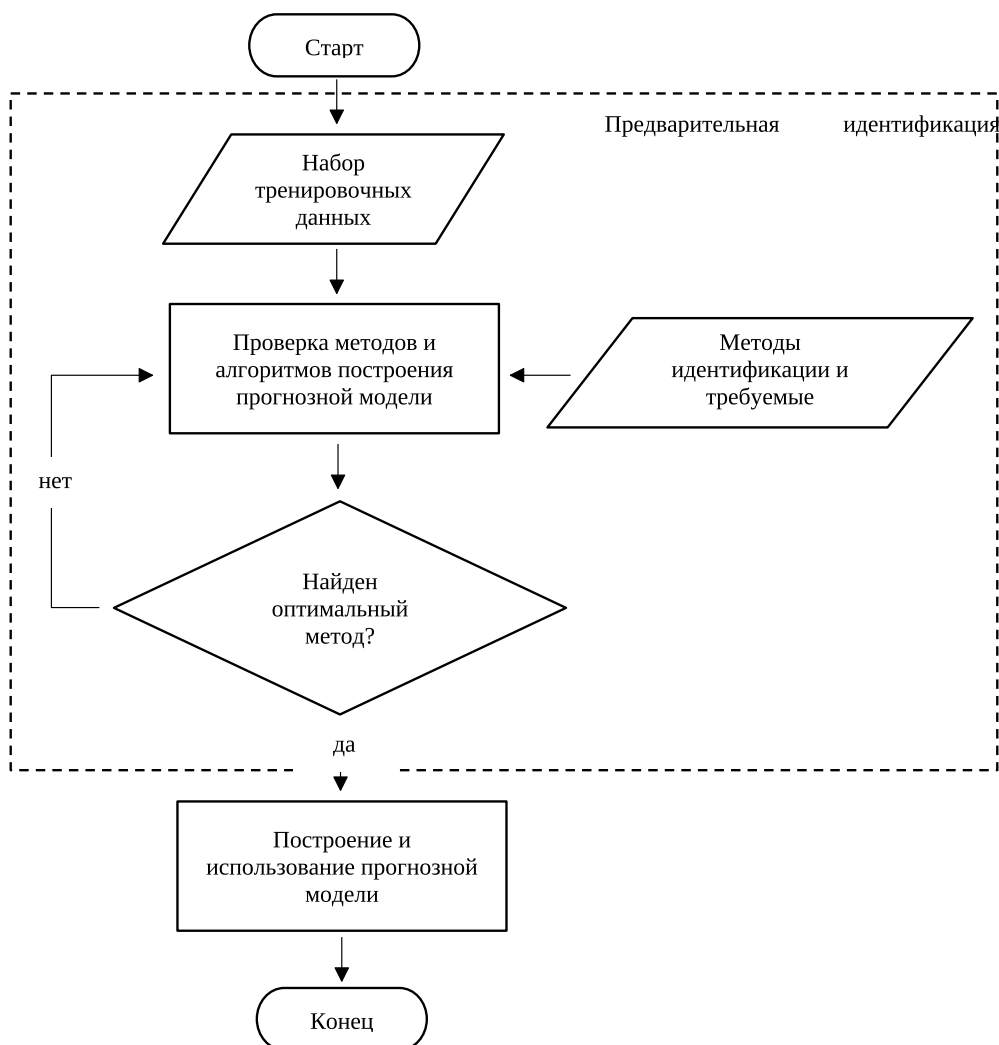


Рис. 3. Алгоритм построения прогнозной модели для требуемых параметров

Заключение

Проектирование и организация транспортно-логистического процесса связаны с наличием существенного количества неопределенных факторов. Методы прогнозирования, основанные на нечетких нейронных сетях, следует использовать как часть системы поддержки принятия решения для анализа факторов, которые могут быть представлены в виде нестационарных временных рядов. Эффективность применения нечеткого нейронного моделирования во многом зависит от методов структурной и параметрической идентификации, выбранных моделей и требуемых параметров. За счет скорости подстройки параметров гибридные нечеткие нейронные модели могут использоваться в режиме онлайн при обработке больших массивов данных, в отличие от более медленных нейронных.

Библиографический список

1. Транспортная стратегия Российской Федерации на период до 2030 года. Министерство транспорта Российской Федерации. — 2008.
2. Дирекция по развитию транспортной системы Санкт-Петербурга и Ленинградской области. Стратегия развития транспортной системы Санкт-Петербурга и Ленинградской области на период до 2030 года. — 2016.
3. Pokrovskaya O. Northern Latitudinal Railway Project: Priorities and Drivers / O. Pokrovskaya, R. Fedorenko, A. Kamaletdinov. — 2021. — DOI: 10.1007/978-3-030-60929-0_34.
4. Anisimov V. Multimodal Transport Network of the Far Eastern Federal District of Russia / V. Anisimov, L. Bogdanova, O. Morozova, S. Shkurnikov, N. Nesterova. — 2021. — DOI: 10.1007/978-981-33-6208-6_45.
5. Panova Yu. Russian Railways on the Eurasian Market: Issue of Sustainability / Yu. Panova, E. Korovyakovskiy, A. Semerkin et al. // European Business Review. — 2017. — 10.1108/EBR-01-2016-0008.
6. Goncharova N. Intelligent Transport Systems as a Way to Improve the Quality of the Rail-Truck Multimodal Freight Transportation / N. Goncharova // IEEE East-West Design & Test Symposium (EWDTS). — 2019. — Pp. 1–7. — DOI: 10.1109/EWDTS.2019.8884460.
7. Jang J.-S. R. ANFIS: adaptive-network-based fuzzy inference system / J.-S. R. Jang // IEEE Transactions on Systems, Man, and Cybernetics. — Vol. 23. — № 3. — Pp. 665–685. — May-June 1993. — doi: 10.1109/21.256541.
8. Zhang J. Recurrent neuro-fuzzy networks for nonlinear process modeling / J. Zhang, A. J. Morris // IEEE Transactions on Neural Networks. — Vol. 10. — № 2. — Pp. 313–326. — March 1999. — doi: 10.1109/72.750562.

9. Yinghua L. Using fuzzy partitions to create fuzzy systems from input-output data and set the initial weights in a fuzzy neural network / L. Yinghua, G. A. Cunningham III, S. Coggeshall // *IEEE Transactions on Fuzzy Systems*. — 1997. — № 5. — Pp. 614–621. — DOI: 10.1109/91.649913.
10. Castellano G. A neuro-fuzzy network to generate human-understandable knowledge from data / G. Castellano, A. Fanelli, C. Mencar // *Cognitive Systems Research Journal*. — 2002. — № 3. — Pp. 125–144. — DOI: 10.1016/S1389-0417(01)00055-9.
11. Lee Shie-Jue. A neuro-fuzzy system modeling with self-constructing rule generation and hybrid SVD-based learning / Shie-Jue Lee, Chen-Sen Ouyang // *Fuzzy Systems, IEEE Transactions on*. — 2003. № 11. — Pp. 341–353. — DOI: 10.1109/TFUZZ.2003.812693.
12. Jiang H. Modeling customer satisfaction for new product development using a PSO-based ANFIS approach / H. Jiang, C. K. Kwong, W. H. Ip, T. C. Wong // *Appl. Soft Comput.* 2012. — № 12. — Pp. 726–734. — DOI: 10.1016/j.asoc.2011.10.020.
13. Catalão J. Hybrid Wavelet-PSO-ANFIS approach for short-term electricity prices forecasting / J. Catalão, H. M. I. Pousinho, V. M. F. Mendes // *Power Systems, IEEE Transactions on*. — 2011. — № 26. — Pp. 137–144. — DOI: 10.1109/TPWRS.2010.2049385.
14. Turki M. Adaptive Control of Nonlinear System Using Neuro-Fuzzy Learning by PSO Algorithm / M. Turki, S. Bouzaida, A. Sakly, M'Sahli Faouzi. — 2012.
15. Pousinho H. M. I. A hybrid PSO-ANFIS approach for short-term wind power prediction in Portugal / H. M. I. Pousinho, V. M. F. Mendes, J. P. S. Catalão // *Energy Conversion and Management*. — 2011— Vol. 52. — Iss. 1. — Pp. 397–402. — ISSN 0196-8904.
16. Peilin L. Training ANFIS Model with an Improved Quantum-Behaved Particle Swarm Optimization Algorithm / L. Peilin, L. Wenhao, W. Fang // *Mathematical Problems in Engineering*. — 2013. — DOI: 10.1155/2013/595639.
17. Bagheri A. Financial forecasting using ANFIS networks with Quantum-behaved Particle Swarm Optimization / A. Bagheri, H. Peyhani, M. Akbari // *Expert Systems with Applications*. — № 41. — Pp. 6235–6250. — DOI: 10.1016/j.eswa.2014.04.003.
18. Soto J. Optimization of the Fuzzy Integrators in Ensembles of ANFIS Model for Time Series Prediction: The case of Mackey-Glass / J. Soto, P. Melin. — 2015. — DOI: 10.2991/ifsaeusflat-15.2015.140.
19. Malleswaran M. Genetically optimized ANFIS based Intelligent Navigation System / M. Malleswaran, V. Vaidehi and R. A. Joseph // *Third International Conference on Advanced Computing*. — 2011. — Pp. 390–395. — DOI: 10.1109/ICoAC.2011.6165207.
20. Cárdenas J. J. Evolutive ANFIS training for energy load profile forecast for an IEMS in an automated factory / J. J. Cárdenas, A. García, J. L. Romeral, K. Kampouropoulos // *ETFA 2011*. — 2011. — Pp. 1–8. — DOI: 10.1109/ETFA.2011.6059079.
21. Zhou Y. Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts / Y. Zhou, S. Guo, F. Chang // *Journal of Hydrology*. — 2019.

22. Wei C. k-NN Based Neuro-fuzzy System for Time Series Prediction / C. Wei, T. Chen, S. Lee // 14th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing. — 2013. — Pp. 569–574. — DOI: 10.1109/SNPD.2013.68.
23. Karaboga D. Training ANFIS using artificial bee colony algorithm / D. Karaboga, E. Kaya // IEEE International Symposium on Innovations in Intelligent Systems and Applications, IEEE INISTA. — 2013. № 1–5. — DOI: 10.1109/INISTA.2013.6577625.
24. Wang R. Assessment of human operator functional state using a novel differential evolution optimization based adaptive fuzzy model / R. Wang, J. Zhang, Y. Zhang, X. Wang // Biomedical Signal Processing and Control. — 2012. — Vol. 7. — Iss. 5. — Pp. 490–498.
25. Orouskhani M. A hybrid method of modified cat swarm optimization and gradient descent algorithm for training anfis / M. Orouskhani, M. Manthouri, Y. Orouskhani, M. Teshnehlab // International Journal of Computational Intelligence and Applications. — 2013. — DOI: 12. 10.1142/S1469026813500077.
26. Badetsky A. Improving the Stability of the Train Formation Plan to Uneven Operational Work / A. Badetsky, O. Medved // Transportation Research Procedia. — 2021. — № 54. — Pp. 559–567. — DOI: 10.1016/j.trpro.2021.02.108.
27. Dolgopолов P. Optimization of train routes based on neuro-fuzzy modeling and genetic algorithms / P. Dolgopолов, D. Konstantinov, L. Rybalchenko, R. Muhitovs // Procedia Comput Sci. — 2019. — № 149. — Pp. 11–18. — DOI: 10.1016/j.procs.2019.01.101
28. Yang L. Railway freight transportation planning with mixed uncertainty of randomness and fuzziness / L. Yang, Z. Gao, K. Li // Appl. Soft Comput. J. — 2011. — № 11.1. — Pp. 778–792. — DOI: 10.1016/j.asoc.2009.12.039.

Дата поступления: 12.05.2022

Решение о публикации: 29.05.2022

Контактная информация:

ЛАМЕХОВ Владимир Андреевич — аспирант; lamekhovva@gmail.com

КОРОВЯКОВСКИЙ Евгений Константинович — канд. техн. наук, проф.; ekorsky@mail.com

Design Algorithm for Forecasting Model of Transport-Logistic Activity on the Basis of Neuro-Fuzzy Networks

V. A. Lamekhov, E. K. Korovyakovsky

Emperor Alexander I Petersburg State Transport University 9, Moskovsky pr., Saint Petersburg, 190031, Russian Federation

For citation: Lamekhov V. A., Korovyakovsky E. K. Design Algorithm for Forecasting Model of Transport-Logistic Activity on the Basis of Neuro-Fuzzy Networks. *Bulletin of scientific research results*, 2022, iss. 3, pp. 137–150. (In Russian) DOI: 10.20295/2223-9987-2022-3-137-150

Summary

Purpose: To consider the current situation in container transportation market of Leningrad Region. To show the need in the design of new forecasting models. To justify the use of neural fuzzy networks. To consider existing limitations of their application. To suggest the ways to build predictive neural fuzzy models for evaluating promising quantitative indicators of logistics activities. **Methods:** ANFIS, R-ANFIS, Fuzzy-Partitions, SCRG, GD, LSE, PSO, ABC, FA. **Results:** The necessity of adaptation of neural fuzzy networks for making forecasts in the field of logistics is pointed on, the structure of a promising model is proposed which takes into account the use and analysis of variety of methods on structural and parametric identification. The shortcomings of particular methods of structural and parametric identification, which affect the accuracy of being obtained forecasts, are indicated. **Practical importance:** The importance of design of accurate predictive models for key quantitative indicators of logistics activities is shown. The factors influencing the implementation of transport and logistics activities are given which of, reliable forecast is impossible in the situation of limited time and resources. For consideration, the article proposes the existing methods of parametric and structural identification of fuzzy neural networks. An algorithm for adapting existing methods to the use in a transport and logistics process is proposed.

Keywords: Fuzzy neural networks, hybrid neural networks, parametric and structural identification methods, learning methods, container terminal, logistics, forecasting.

References

1. *Transportnaya strategiya Rossiyskoy Federatsii na period do 2030 goda*. Ministerstvo transporta Rossiyskoy Federatsii [Transport strategy of the Russian Federation for the period up to 2030. Ministry of Transport of the Russian Federation]. 2008. (In Russian)
2. *Direktsiya po razvitiyu transportnoy sistemy Sankt-Peterburga i Leningradskoy oblasti. Strategiya razvitiya transportnoy sistemy Sankt-Peterburga i Leningradskoy oblasti na period do 2030 goda* [Directorate for the development of the transport system of St. Petersburg and the Leningrad region. Strategy for the development of the transport system of St. Petersburg and the Leningrad region for the period up to 2030]. 2016. (In Russian)
3. Pokrovskaya O., Fedorenko R., Kamaletdinov A. Northern Latitudinal Railway Project: Priorities and Drivers. 2021. DOI: 10.1007/978-3-030-60929-0_34.

4. Anisimov V., Bogdanova L., Morozova O., Shkurnikov S., Nesterova N. Multimodal Transport Network of the Far Eastern Federal District of Russia. 2021. DOI: 10.1007/978-981-33-6208-6_45.
5. Panova Yu., Korovyakovskiy E., Semerkin A. Russian Railways on the Eurasian Market: Issue of Sustainability. *European Business Review*. 2017. DOI: 10.1108/EBR-01-2016-0008.
6. Goncharova N. Intelligent Transport Systems as a Way to Improve the Quality of the Rail-Truck Multimodal Freight Transportation. *IEEE East-West Design & Test Symposium (EWDTS)*. 2019, pp. 1–7. DOI: 10.1109/EWDTS.2019.8884460.
7. Jang J.-S. R. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, I. 3, pp. 665–685. DOI: 10.1109/21.256541.
8. Zhang J., Morris A. J. Recurrent neuro-fuzzy networks for nonlinear process modeling. *IEEE Transactions on Neural Networks*, vol. 10, I. 2, pp. 313–326. DOI: 10.1109/72.750562.
9. Yinghua L., Cunningham III G. A., Coggeshall S. Using fuzzy partitions to create fuzzy systems from input-output data and set the initial weights in a fuzzy neural network. *IEEE Transactions on Fuzzy Systems*. 1997, I. 5, pp. 614–621. DOI: 10.1109/91.649913.
10. Castellano G., Fanelli A., Mencar C. A neuro-fuzzy network to generate human-understandable knowledge from data. *Cognitive Systems Research Journal*. 2002, I. 3, pp. 125–144. DOI: 10.1016/S1389-0417(01)00055-9.
11. Lee Shie-Jue, Chen-Sen Ouyang. A neuro-fuzzy system modeling with self-constructing rule generation and hybrid SVD-based learning. *Fuzzy Systems, IEEE Transactions on*. 2003, I. 11, pp. 341–353. DOI: 10.1109/TFUZZ.2003.812693.
12. Jiang H., Kwong C. K., Ip W. H., Wong T. C. Modeling customer satisfaction for new product development using a PSO-based ANFIS approach. *Appl. Soft Comput.* 2012, I. 12, pp. 726–734. DOI: 10.1016/j.asoc.2011.10.020.
13. Catalão J., Pousinho H. M. I., Mendes V. M. F. Hybrid Wavelet-PSO-ANFIS approach for short-term electricity prices forecasting. *Power Systems, IEEE Transactions on*. 2011, I. 26, pp. 137–144. DOI: 10.1109/TPWRS.2010.2049385.
14. Turki M., Bouzaida S., Sakly A., M'Sahli Faouzi. *Adaptive Control of Nonlinear System Using Neuro-Fuzzy Learning by PSO Algorithm*. 2012.
15. Pousinho H. M., Mendes V. M. F., Catalão J. P. S. I. A hybrid PSO–ANFIS approach for short-term wind power prediction in Portugal. *Energy Conversion and Management*. 2011, vol. 52, I. 1, pp. 397–402.
16. Peilin L., Wenhao L., Fang W. Training ANFIS Model with an Improved Quantum-Behaved Particle Swarm Optimization Algorithm. *Mathematical Problems in Engineering*. 2013. DOI: 10.1155/2013/595639.
17. Bagheri A., Peyhani H., Akbari M. Financial forecasting using ANFIS networks with Quantum-behaved Particle Swarm Optimization. *Expert Systems with Applications*. I. 41, pp. 6235–6250. DOI: 10.1016/j.eswa.2014.04.003.
18. Soto J., Melin P. Optimization of the Fuzzy Integrators in Ensembles of ANFIS Model for Time Series Prediction: The case of Mackey-Glass. 2015. DOI: 10.2991/ifsa-eusflat-15.2015.140.

19. Malleswaran M., Vaidehi V., Joseph R. A Genetically optimized ANFIS based Intelligent Navigation System. Third International Conference on Advanced Computing. 2011, pp. 390–395. DOI: 10.1109/ICoAC.2011.6165207.
20. Cárdenas J. J., García A., Romeral J. L., Kampouropoulos K. Evolutive ANFIS training for energy load profile forecast for an IEMS in an automated factory. ETFA 2011. 2011, pp. 1–8. DOI: 10.1109/ETFA.2011.6059079.
21. Zhou Y., Guo S., Chang F. Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts. Journal of Hydrology. 2019.
22. Wei C., Chen T., Lee S. k-NN Based Neuro-fuzzy System for Time Series Prediction. 14th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing. 2013, pp. 569–574. DOI: 10.1109/SNPD.2013.68.
23. Karaboga D., Kaya E. Training ANFIS using artificial bee colony algorithm. IEEE International Symposium on Innovations in Intelligent Systems and Applications, IEEE INISTA. 2013. I. 1–5. DOI: 10.1109/INISTA.2013.6577625.
24. Wang R., Zhang J., Zhang Y., Wang X. Assessment of human operator functional state using a novel differential evolution optimization based adaptive fuzzy model. Biomedical Signal Processing and Control. 2012, vol. 7, I. 5, pp. 490–498.
25. Orouskhani M., Manthouri M., Orouskhani Y., Teshnehlab M. A hybrid method of modified cat swarm optimization and gradient descent algorithm for training anfis. International Journal of Computational Intelligence and Applications. 2013. DOI: 12. 10.1142/S1469026813500077.
26. Badetsky A., Medved O. Improving the Stability of the Train Formation Plan to Uneven Operational Work. Transportation Research Procedia. 2021, I. 54, pp. 559–567. DOI: 10.1016/j.trpro.2021.02.108.
27. Dolgoplov P., Konstantinov D., Rybalchenko L., Muhitovs R. Optimization of train routes based on neuro-fuzzy modeling and genetic algorithms. Procedia Comput Sci. 2019, I. 149, pp. 11–18. DOI: 10.1016/j.procs.2019.01.101
28. Yang L., Gao Z., Li K. Railway freight transportation planning with mixed uncertainty of randomness and fuzziness. Appl. Soft Comput. J. 2011, I. 11.1, pp. 778–792. DOI: 10.1016/j.asoc.2009.12.039.

Received: May 12, 2022

Accepted: May 29, 2022

Author's information:

Vladimir A. LAMEKHOV — Postgraduate Student; lamekhovva@gmail.com

Evgeniy K. KOROVYAKOVSKIY — PhD in Technical Sciences, Professor; ekorsky@mail.com