

АЗЕРБАЙДЖАНСКАЯ РЕСПУБЛИКА

На правах рукописи

РАЗРАБОТКА МЕТОДОВ И АЛГОРИТМОВ ПРОГНОЗИРОВАНИЯ НЕЧЕТКИХ ВРЕМЕННЫХ РЯДОВ

Специальность: 3338.01 – «Системный анализ,
управление и обработка информации»

Отрасль науки: Техника

Соискатель: **Пярвин Эльчин гызы Ализаде**

АВТОРЕФЕРАТ

диссертация на соискание учёной степени
доктора философии

Баку – 2024

Диссертационная работа выполнена в Бакинском государственном университете

Научный руководитель: Доктор технических наук,
профессор **Рамин Рза оглы Рзаев**

Официальные оппоненты: Доктор технических наук, профессор
Фазиль Хазин оглы Алекперли

Доктор технических наук, доцент
Кямаля Рафиг гызы Алиева


Доктор философии по технике, доцент
Рахиб Айдын оглы Имамгулиев

Диссертационный совет ED 2.48 Высшей Аттестационной Комиссии при Президенте Азербайджанской Республики, действующей на базе Азербайджанского Государственного Университета Нефти и Промышленности.

Председатель
диссертационного совета: Доктор технических наук, профессор


Рафик Азиз оглы Алиев

Ученый секретарь
диссертационного совета: Доктор философии по технике, доцент


Акиф Вели оглы Ализаде

Председатель научного
семинара: Доктор технических наук, профессор


Мухаммед Нурмухаммед оглу Нуриев



ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы и степень ее разработанности. Основной особенностью социально-экономических систем является их сложное поведение, которое характеризуется волатильной динамикой. Поэтому не удивительно, что соответствующие поведениям социально-экономических систем временные ряды отличаются высокой степенью неопределенности. Главными причинами такой неопределенности являются нестационарность исследуемых процессов, недостаточная длительность и точность наблюдений, а также слабовыраженный тренд и/или просто ненаблюдаемая тенденция развития. Наличие перечисленных свойств в волатильности поведения временного ряда предопределяет причины, согласно которым исследование динамических рядов все чаще рассматривается с применением различных методов нелинейной динамики: теории хаоса и фрактальной геометрии, нечеткой логики и теории нечетких множеств, теории нейронных сетей и систем гибридного моделирования.

Прогнозирование временных рядов в нечеткой парадигме не претендуют на высокую точность прогнозирования и в основном применяется для краткосрочного планирования, например, для прогнозирования тенденций на рынке труда. Нечеткие временные ряды скорее ориентированы на формирование качественной информации о динамике поведения изучаемой системы и обеспечивают информационную поддержку принятия решений как один из инструментов интеллектуального анализа данных. Другими словами, нечеткие временные ряды стали составной частью технологии Data Mining, основными направлениями которой являются анализ и моделирование процессов, протекающих в условиях неопределенности, включая неопределенности нестохастического типа; выявление скрытых закономерностей и компиляция новых знаний, например, в виде прогнозируемых временных рядов.

Таким образом, исследование контекстных данных и анализ методов исследования закономерностей между ними сформировали новое практическое направление – интеллектуальный анализ данных или Data Mining. На протяжении последних двух десятилетий усилиями ряда зарубежных ученых, например, таких как К. Хирота, Х. Танак, В. Педрич и Я. Капржик, исследованы методы нечеткой регрессии и анализа данных нечетких временных рядов. Среди азербайджанских ученых в первую очередь следует отметить работы Р. Алиева, К. Иманова, Р. Рзаева, которые внесли существенный вклад в область изучения поведения социально-экономических систем в условиях неопределенности.

Родоначальниками теории нечетких временных рядов являются К. Сонг и Б. Чиссом, которые предложили методологию прогнозирования слабо структурированных динамических рядов с использованием техники нечетких отношений и приближенного вывода. Далее это направление стремительно развивалось усилиями, прежде всего, С. Чена, нечеткие модели которого существенно упростили вычисления, Н. Кумара, К. Ченга, Дж. Поулсена и др. Предложенные ими подходы к прогнозированию нечетких временных рядов отличаются правилами фаззификации исторических данных и дефаззификации выходов нечетких прогностических моделей.

Методы анализа временных рядов в нечеткой парадигме уже завоевали право стать основой для создания библиотек интерактивных моделей (симуляций) для поддержки принятия решений в самых разных сферах управления. Однако, несмотря на достигнутые результаты, многие задачи анализа нечетких временных рядов остаются нерешенными, в частности, задачи выявления внутренних нечетких тенденций и генерации правил их распознавания. Исходя из сказанного становится очевидным важность и актуальность перечисленных особенностей для дальнейшего развития инструментария по прогнозированию поведения слабо структурированных систем на основе нечетких временных рядов.

Основная цель и задачи исследования. Основной целью диссертационной работы является исследование прогностических возможностей нечетких тенденций слабо структурированных временных рядов, разработка новых правил фаззификации исторических данных и дефаззификации нечетких прогнозов, а также построение соответствующей адекватной математической модели для прогнозирования волатильных временных рядов.

Для достижения поставленной цели на примере динамики изменения промышленного индекса Доу Джонса за более чем годичный период планируется решить следующие составные задачи:

- провести сравнительный анализ существующих методов фаззификации исторических данных временных рядов, выявить их возможности и недостатки;
- разработать новое правило для фаззификации слабо структурированных исторических данных, как для случая фиксированного произвольного набора качественных критериев оценки, так и для случая обоснованного выбора их количества;
- построить методику для выявления нечетких тенденций временных рядов и методику анализа временного ряда нечетких тенденций;
- разработать алгоритм для восстановления нечеткого временного ряда по исходному временному ряду и обратный алгоритм генерации ряда в номинальных величинах;
- разработать метод компиляции знаний о внутренних нечетких тенденциях в форме импликативных правил;
- разработать и реализовать программную оболочку в виде инструмента обработки исторических данных для восстановления и прогнозирования временного ряда;
- разработать нейро-сетевую модель для прогнозирования временного ряда в номинальных величинах.

Объект и предмет исследования. Объектом исследования является волатильный нечеткий временной ряд, а предмет исследования составляет методы выявления внутренних

нечетких закономерностей временных рядов и методы моделирования временного ряда нечетких тенденций.

Применяемая методика исследования. При написании диссертации применялись общенаучные методы исследования, такие как диалектический метод, комплексный анализ, синтез и пр., и специальные научные методы, подразумевающие системный и формально-логический подходы, учитывающие существующие наработки фундаментальных и прикладных исследований по проблемам принятия решений в условиях неопределенности, представленных в работах республиканских и зарубежных ученых. Намеченная цель и основные задачи диссертации предопределили необходимость применения междисциплинарного подхода, обеспечивающего органичность вычислений с применением количественных и качественных категорий, статистического анализа и обобщения. При этом, анализ установленных научных положений и применение методологического аппарата – элементы нечеткой логики и современная теория нечетких множеств, методы математической статистики, теория нейронных сетей, на конкретных примерах формируют доказательную базу и обеспечивают достоверность полученных выводов.

Теоретическую и информационно-эмпирическую базу диссертационного исследования составляют ряд статистических данных из открытых источников Интернета, работы ведущих республиканских и зарубежных ученых в предметной области, репрезентативная совокупность которых обеспечила аргументированную обоснованность практических рекомендаций.

Достоверность результатов диссертационной работы. Достоверность научных положений, выводов и рекомендаций подтверждена результатами проведенных экспериментов, а также результатами использования материалов диссертации и разработанной прикладной методологии в профильной организации в соответствии с актом внедрения.

Основные положения, выносимые на защиту.

- Временной ряд нечетких закономерностей является эффективным индикатором волатильного развития моделируемого процесса на фондовой бирже, который описан в качественных категориях по средствам термов лингвистических переменных
- Ключевыми операциями обработки нечетких закономерностей являются алгоритмы обработки внутренних нечетких связей, а именно, методика восстановления нечеткого временного ряда по исходному временному ряду и обратная операция компиляции временного ряда в номинальных величинах, как отражение идентифицированных нечетких тенденций
- Трехслойная нейронная сеть предложенной топологии является результативным компилятором правил прогнозирования нечетких тенденций, выраженных в виде дефазифицированных значений нечетких интерпретаций исторических данных
- Разработанная прогностическая модель на основе временных рядов нечетких тенденций позволяет прогнозировать волатильный временной ряд на краткосрочный период.
- Разработанная нейросетевая модель выбранной топологии позволяет прогнозировать волатильный временной ряд на краткосрочный период.

Научная новизна в исследовании. Научная новизна диссертационной работы состоит в следующем:

- Предложено определение временного ряда в нечеткой парадигме и разработана новый метод распознавания внутренних нечетких тенденций
- Разработаны алгоритмы обработки внутренних нечетких тенденций, включая операцию восстановления нечеткого временного ряда по историческим данным исходного временного ряда и обратная операция генерации ряда в номинальных величинах
- Предложен метод фаззификации слабо структурированных данных с применением системы нечеткого вывода

- Предложен метод компиляции знаний о внутренних нечетких закономерностях в форме импликативных правил и с применением нейро-сетевой модели
- Разработана прогностическая модель на основе временных рядов нечетких тенденций, позволяющая прогнозировать волатильный временной ряд на краткосрочный период
- Исследована эффективность прогностических моделей, составленных на основе временных рядов нечетких тенденций и методов нейро-сетевого распознавания, с применением среднестатистических критериев оценки.

Научно-практическая значимость исследования.

Разработанные методы и алгоритмы позволяют потенциальным пользователям создавать прогностические модели волатильных временных рядов с улучшенными качественными характеристиками и, тем самым, существенно сокращать время, затрачиваемое на принятие оперативных решений.

Апробация и внедрения работы. Основные положения и результаты диссертации докладывались, обсуждались и получили одобрение на:

- the 7th International Conference on Control and Optimization with Industrial Applications, COIA – 2020 (2020, Baku, Azerbaijan)
- the 14th International Conference on Applications of Fuzzy Systems, Soft Computing and Artificial Intelligence Tools, ICAFS – 2020 (2020, Budva, Montenegro),
- the 11th International Conference on Theory and Application of Soft Computing, Computing with Words, Perception and Artificial Intelligence ICSCCW-2021, (2021, Antalya, Turkey)
- the 8th World Conference on Soft Computing dedicated to the 100th Birthday anniversary and research heritage of professor Lotfy A. Zadeh (2022, Baku, Azerbaijan)
- the Future of Information and Communication Conference, FICC – 2022 (2022, San Francisco, USA)
- the Intelligent Systems Conference, IntelliSys – 2023, (2023, Amsterdam, The Netherlands),

а также на расширенных семинарах кафедры «Информационные Технологии и Программирование» факультета Прикладной

математики и кибернетики Бакинского Государственного Университета и лаборатории «Информационные системы поддержки принятия решений» Института Систем Управления Министерства по Науке и Образованию Азербайджанской Республики.

Наименование организации, где работа выполнена. Диссертационная работа была выполнена на кафедре «Информационные Технологии и Программирование» факультета «Прикладная Математика и Кибернетика» Бакинского Государственного Университета.

Публикации результатов диссертационной работы. По теме диссертации опубликовано 17 работ, в том числе, 8 тезисов-докладов и 9 статей, в том числе 6 – за рубежом, из которых 5 статей опубликованы в журналах с международными научными индексами цитирования из архива Web-Science и SCOPUS.

Личный вклад. Все результаты, составляющие содержание диссертации, получены автором самостоятельно.

Структура и объем диссертационной работы. Диссертационная работа состоит из введения, 3-х глав, заключения и списка использованной литературы. Работа изложена на 123 страницах машинописного текста, содержит 68 рисунков и 15 таблиц, состоит из введения, трех глав, заключения, списка литературы из 100 наименований. Объем общего и структурного разделов диссертации распределяется примерно следующим образом:

- всего – 235 119 знаков,
- оглавление – 1 819 знаков,
- введение – 12 749 знаков,
- глава первая – 27 482 знаков,
- глава вторая – 137 525 знаков,
- глава третья – 54 552 знаков,
- результат – 992 знаков.

СОДЕРЖАНИЕ

Во введении диссертации изложена актуальность исследования, сформулирована основная её цель и приведён перечень задач и подходов, необходимых для реализации этой цели, описана структура и содержание работы, а также полученные результаты, выносимые на защиту.

В первой главе рассматриваются современные методы анализа динамических рядов. В лаконичной форме описаны существующие возможности и ограничения статистических и интеллектуальных методов моделирования временных рядов. Так, концептуальная статистическая модель временного ряда представляется в общем виде как

$$x(t) = \lambda \cdot f(t) + \psi \cdot \varepsilon_t + \xi_t,$$

где историческая данная $x(t)$ рассматривается как сумма некоторой систематической компоненты $f(t)$ и случайной компоненты ε ; λ и ψ являются коэффициентами, принимающие значения из множества $\{0, 1\}$; ξ_t – случайная ошибка с нулевым математическим ожиданием и конечной дисперсией. При этом, несмотря на разнообразный инструментарий статистического анализа, не всегда удаётся успешно построить прогностические модели, обеспечивающие достоверность экстраполяции данных и соответствие поведения модели поведению исходного временного ряда.

Нейро-сетевое моделирование сводится к решению задачи аппроксимации нелинейной непрерывной функции от многих переменных по установленному заранее набору обучающих примеров из истории временного ряда. В общем виде нейро-сетевая модель временного ряда выглядит в следующем виде:

$$\hat{y}_{k+1} = \phi(y_k, y_{k-1}, \dots, y_{k-n+1}) + \varepsilon_{k+1},$$

где $\hat{y}_{k+1}$ является прогнозом; $y_k, y_{k-1}, \dots, y_{k-n+1}$ наблюдаемые значения временного ряда; $\phi(y_k, y_{k-1}, \dots, y_{k-n+1})$ – нелинейная непрерывная функция $(n-1)$ переменных, параметрической моделью которой может служить, например, трёхслойная

нейронная сеть; ε_{k+1} – допустимая погрешность прогнозирования; n – порядок модели.

Особое внимание уделено использованию теории нечетких множеств, которые применяются для управления и моделирования слабо структурированных и сложных процессов. Изложены основные положения теории нечетких множеств и описаны модели нечетких временных рядов. Для введения нечёткости отправным является построение универсума, который в случае моделирования и прогнозирования временного ряда является покрытие диапазона исторических данных

$$d = [D_{\min} - D_1; D_{\max} + D_2],$$

где $D_{\min}$ и $D_{\max}$ – соответственно минимальное и максимальное значения среди данных временного ряда; $D_1 > 0$ и $D_2 > 0$ выбираются из расчёта деления отрезка d на равные интервалы u_j по числу выбранных критериев оценки $C_1, C_2, \dots, C_n$, которые в общем виде задаются в виде следующих нечетких множеств:

$$C_1 = \mu_{C_1}(u_1)/u_1 + \mu_{C_1}(u_2)/u_2 + \dots + \mu_{C_1}(u_n)/u_n,$$

$$C_2 = \mu_{C_2}(u_1)/u_1 + \mu_{C_2}(u_2)/u_2 + \dots + \mu_{C_2}(u_n)/u_n,$$

...

$$C_n = \mu_{C_n}(u_1)/u_1 + \mu_{C_n}(u_2)/u_2 + \dots + \mu_{C_n}(u_n)/u_n,$$

где $\mu_{C_i}(u_j) \in [0, 1]$ ($i, j = 1 \div n$) – значения функции принадлежности интервала u_j к нечеткому множеству C_i .

Объектом исследования диссертации является временной ряд индекса Доу Джонса (DJIA – Dow Jones Industrial Average) $\{x(t)\}$ ($t = 1 \div T$) (Рис. 1), в котором $x(t)$ рассматривается как слабо структурированная данная или нечётким множеством A_j ($j = 1 \div J$), характеризуемый картежом [1]:

$$\{x(t)/\mu_{A_j}[x(t)]\}, \mu_{A_j}[x(t)]: U \rightarrow [0, 1],$$

где U является дискретным универсумом, покрывающим диапазон показателей DJIA.




Рис. 1. Временной ряд DJIA

Основная задача заключается в разработке метода фаззификации показателей DJIA, который позволил бы более адекватно восстановить временной ряд DJIA $\{x(t)\}$ в терминах нечётких множеств и, тем самым, построить более адекватную математическую модель ряда для прогнозирования в номинальных единицах.

Во второй главе предлагается подход к фаззификации исторических данных, основанный на применении системы Fuzzy Inference System (FIS), построенной на тривиальных утверждениях:

e_1 : «Если индекс DJIA расположен ближе к середине отрезка u_1 , то его величина является слишком низкой»;

e_2 : «Если индекс DJIA расположен ближе к середине отрезка u_2 , то его величина является очень низкой»;

e_3 : «Если индекс DJIA расположен ближе к середине отрезка u_3 , то его величина является более чем низкой»;

e_4 : «Если индекс DJIA расположен ближе к середине отрезка u_4 , то его величина является низкой»;

e_5 : «Если индекс DJIA расположен ближе к середине отрезка u_5 , то его величина является высокой»;

e_6 : «Если индекс DJIA расположен ближе к середине отрезка u_6 , то его величина является более чем высокой»;

e_7 : «Если индекс DJIA расположен ближе к середине отрезка u_7 , то его величина является очень высокой»;

е8: «Если индекс DJIA расположен ближе к середине отрезка u_8 , то его величина является слишком высокой».

Анализ этих высказываний, как отражающих причинно-следственные связи, позволил определить входную характеристику в виде лингвистической переменной x = «Локализация индекса DJIA», принимающей значения в виде термов «БЛИЖЕ К СЕРЕДИНЕ ОТРЕЗКА u_j » ($j=1\div 8$): $u_1=[21771, 22471]$, $u_2=[22471, 23171]$, ..., $u_8=[26671, 27371]$, и выходную лингвистическую переменную y = «Величина индекса DJIA», значениями которой являются термы: «СЛИШКОМ НИЗКАЯ», «ОЧЕНЬ НИЗКАЯ», «БОЛЕЕ ЧЕМ НИЗКАЯ», «НИЗКАЯ», «ВЫСОКАЯ», «БОЛЕЕ ЧЕМ ВЫСОКАЯ», «ОЧЕНЬ ВЫСОКАЯ», «СЛИШКОМ ВЫСОКАЯ». Вербальные оценки локализации индекса DJIA $x(t)$ по признаку его принадлежности локальному отрезку u_j ($j=1\div 8$) отображены в виде нечётких подмножеств дискретного универсума $U=[21771, 27371]$, включающего показатели индекса DJIA за 333 дней торгов на фондовой бирже: $U = \{x(t)\}_{t=1}^{333}$. В качестве функции принадлежности применяется функция Гауссовского типа (Рис. 2.)

$$\mu(x) = \exp [-(x_i - u_{j0})^2 / \sigma^2], \quad (1)$$

где $x_t = x(t)$ – показатель индекса DJIA, установленный по итогам торгов на фондовой бирже в t -ый день; u_{j0} – середина интервала u_j ($j=1\div 8$); σ – стандартное отклонение, выбранное единым для всех случаев в виде числа 500.




Рис. 2. Функции принадлежности нечётких множеств, отражающих степень локализации индекса DJIA

Определив середины отрезков u_i как: $u_{10}=22121$, $u_{20}=22821$, ..., $u_{80}=27021$, в соответствии с (1) признаки локализации индекса DJIA $x_t = x(t)$ ($t = 1 \div 333$) могут быть интерпретированы как:

- «БЛИЗОСТЬ К 22121» в виде нечёткого множества:
 $X_1=0.952181/x_1+0.958630/x_2+\dots+0.000793/x_{332}+0.000472/x_{333}$;
- «БЛИЗОСТЬ К 22821» в виде нечёткого множества:
 $X_2=0.643393/x_1+0.656883/x_2+\dots+0.006941/x_{332}+0.004497/x_{333}$;
-
- «БЛИЗОСТЬ К 27021» в виде нечёткого множества:
 $X_8=0.000016/x_1+0.000018/x_2+\dots+0.833393/x_{332}+0.895873/x_{333}$.

Термы выходной лингвистической переменной «Величина индекса DJIA» описаны в виде нечётких подмножеств дискретного универсума $I = \{0, 0.1, 0.2, \dots, 1\}$, т.е. $\forall i \in I$ как: TL =СЛИШКОМ НИЗКОЕ: $\mu_{TL}(i)=0$, если $i=1$ и $\mu_{TL}(i)=1$, если $i<1$; VL =ОЧЕНЬ НИЗКОЕ: $\mu_{VL}(i)=(1-i)^2$; ML =БОЛЕЕ ЧЕМ НИЗКОЕ: $\mu_{ML}(i)=(1-i)^{(1/2)}$; L =НИЗКОЕ: $\mu_L(i)=1-i$; H =ВЫСОКОЕ: $\mu_H(i)=i$; MH =БОЛЕЕ ЧЕМ ВЫСОКОЕ: $\mu_{MH}(i)=i^{(1/2)}$; VH =ОЧЕНЬ ВЫСОКОЕ: $\mu_{VH}(i)=i^2$; TH =СЛИШКОМ ВЫСОКОЕ: $\mu_{TH}(i)=1$, если $i=1$ и $\mu_{TH}(i)=0$, если $i<1$.

В результате применения нечеткой импликации Лукасевича

$$\mu_{\Pi}(u, i) = \min\{1, 1 - \mu_X(u) + \mu_X(i)\}, \quad (2)$$

определены нечеткие отношения в виде матриц $R_1, R_2, \dots, R_8$ размером 333×11 , пересечение которых дало общее функциональное решение $R=R_1 \cap R_2 \cap \dots \cap R_8$ в виде следующей матрицы

	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
$x_1 = 25090.5$	0.0114	0.1114	0.2114	0.3114	0.4114	0.5114	0.6114	0.5610	0.4610	0.3610	0.2610
$x_2 = 24987.5$	0.0018	0.1018	0.2018	0.3018	0.4018	0.5018	0.6018	0.5094	0.4094	0.3094	0.2094
$x_3 = 24700.2$	0.0193	0.1193	0.2193	0.3193	0.4193	0.5193	0.4878	0.3878	0.2878	0.1878	0.0878
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_{332} = 26346.0$	0.0002	0.0102	0.0402	0.0902	0.1602	0.1666	0.1666	0.1666	0.1666	0.1666	0.8357
$x_{333} = 26496.7$	0.0123	0.0223	0.0523	0.1023	0.1041	0.1041	0.1041	0.1041	0.1041	0.1041	0.8740

которая отражает причинно-следственную связь между признаками локализации индекса DJIA, с одной стороны, и его величиной – с другой. В результате, все исторические данные временного ряда индекса DJIA интерпретируются в виде

соответствующих нечётких множеств (НМ), которые сведены в Таблицу 1.

Таблица 1. Детализированный нечёткий временной ряд индекса DJIA

Дата	НМ	Значения функции принадлежности нечёткого аналога индекса DJIA						ТО НМ
		0	0.1	0.2	...	0.9	1	
15.06.2018	A_1	0.0114	0.1114	0.2114	...	0.3610	0.2610	0.6062
18.06.2018	A_2	0.0018	0.1018	0.2018	...	0.3094	0.2094	0.5939
19.06.2018	A_3	0.0193	0.1193	0.2193	...	0.1878	0.0878	0.5330
20.06.2018	A_4	0.0273	0.1273	0.2273	...	0.1735	0.0735	0.5219
.....								
07.10.2019	A_{330}	0.0098	0.0198	0.0498	...	0.1113	0.8697	0.9513
08.10.2019	A_{331}	0.0098	0.0198	0.0498	...	0.2546	0.7791	0.8959
09.10.2019	A_{332}	0.0002	0.0102	0.0402	...	0.1666	0.8357	0.9321
10.10.2019	A_{333}	0.0123	0.0223	0.0523	...	0.1041	0.8740	0.9534

Как показано на Рис. 3, динамический ряд индекса DJIA в терминах точечных оценок нечетких множеств (ТО НМ) приближенно точно воспроизводит конфигурацию временного ряда DJIA в масштабе отрезка $[0, 1]$.



Рис. 3. Временной ряд индекса DJIA в нотации ТО НМ

Число НМ, представленных в Таблице 1, является избыточным для формирования совокупности качественных критериев оценки. Поэтому по следующей схеме было установлено их оптимальное число для проведения оценочных суждений

Шаг 1. Сортировка исторических показателей x_t ($t=1\div 333$) индекса DJIA в виде возрастающей последовательности $\{x_{p(i)}\}$, где p является перестановкой, сортирующей значения индекса

DJIA в порядке их возрастания по тривиальному правилу $x_{p(i)} \leq x_{p(i+1)}$.

Шаг 2. На совокупности всех попарных расстояний $d_i = |x_{p(i)} - x_{p(i+1)}|$ между любыми двумя последовательными значениями $x_{p(i)}$ и $x_{p(i+1)}$ вычисление среднего расстояния AD по формуле

$$AD = \sum_{i=1}^{n-1} |x_{p(i)} - x_{p(i+1)}| / (n-1), \quad (3)$$

и соответствующего стандартного отклонения σ_{AD} формуле

$$\sigma_{AD} = \sqrt{\sum_{i=1}^{n-1} (d_i - AD)^2 / (n-1)}. \quad (4)$$

Шаг 3. Выявление и сброс аномальных величин, подлежащих устранению. Исключению из рассмотрения подлежат величины попарных расстояний, которое не удовлетворяют условию:

$$AD - \sigma_{AD} \leq d_i \leq AD + \sigma_{AD}. \quad (5)$$

Шаг 4. Повторный расчет средней величины AD на совокупности попарных расстояний, оставшихся после сортировки с учётом сброса аномалий.

Шаг 5. Установление оптимального числа качественных критериев оценки исторических показателей промышленного индекса DJIA в виде НМ по формуле

$$m = (D_2 - D_1 - AD) / (2 \cdot AD), \quad (6)$$

где $D_1 = D_{\min} - AD$, $D_2 = D_{\max} + AD$.

В результате выполнения этих процедур для временного ряда DJIA при $n = 333$ было установлено число критериев как $m = 280$. Тогда, полагая F_1 и F_{333} ТО для НМ A_1 и A_{333} , соответственно, отрезок $[F_1, F_{333}]$ разбивается на 280 равных отрезков a_k ($k = 1 \div 280$) с длинами $(F_{333} - F_1) / 280$. В этом случае все НМ A_t ($t = 1 \div 333$) группируются посредством применения импликативного правила:

«Если ТО НМ A_t из отрезка a_k , то A_t входит в k -ю группу».

В результате были сформированы 144 группы, внутри которых формализуются качественные критерии оценки исторических показателей индекса DJIA, которые сведены в Таблицу 2.

Таблица 2. Качественные критерии оценки индекса DJIA

Критерий оценки	Значения функции принадлежности нечеткого подмножества универсума						
	0	0.1	0.2	0.3	...	0.9	1
C_1	0.9138	0.0412	0.0412	0.0412	...	0.0412	0.0412
C_2	0.8644	0.1200	0.1200	0.1200	...	0.0172	0.0072
C_3	0.8173	0.1960	0.1960	0.1960	...	0.0106	0.0006
C_4	0.8115	0.2051	0.2051	0.2051	...	0.0113	0.0013
.....							
C_{141}	0.0117	0.0217	0.0217	0.0217	...	0.0217	0.8730
C_{142}	0.0147	0.0147	0.0147	0.0147	...	0.0147	0.9297
C_{143}	0.0091	0.0091	0.0091	0.0091	...	0.0091	0.9351
C_{144}	0.0010	0.0010	0.0010	0.0010	...	0.0010	0.9423

В терминах НМ C_k ($k=1\div 144$) временной ряд ДЛИА, а также его интерпретация в нотации ТО НМ представлены в Таблице 3.

Таблица 3. Временной ряд ДЛИА в терминах НМ и ТО

№	Дата	ДЛИА	НМ	ТО	Кр.	Детализация	ТО
1	15.06.2018	25090.5	A_1	0.6062	C_{55}	$A_1 \cap A_{107} \cap A_{164}$	0.6051
2	18.06.2018	24987.5	A_2	0.5939	C_{51}	$A_2 \cap A_{93}$	0.5936
3	19.06.2018	24700.2	A_3	0.5330	C_{41}	$A_3 \cap A_{18} \cap A_{150}$	0.5335
4	20.06.2018	24657.8	A_4	0.5219	C_{39}	A_4	0.5219
.....							
156	29.01.2019	24580.0	A_{156}	0.5022	C_{36}	$A_6 \cap A_{92} \cap A_{156}$	0.5026
157	30.01.2019	25014.9	A_{157}	0.5975	C_{52}	$A_{157} \cap A_{158}$	0.5956
158	31.01.2019	24999.7	A_{158}	0.5956	C_{52}	$A_{157} \cap A_{158}$	0.5956
159	01.02.2019	25063.9	A_{159}	0.6033	C_{54}	$A_{21} \cap A_{24} \cap A_{25} \cap A_{83} \cap A_{159} \cap A_{165}$	0.6021
.....							
330	07.10.2019	26478.0	A_{330}	0.9513	C_{131}	$A_{71} \cap A_{80} \cap A_{285} \cap A_{330} \cap A_{333}$	0.9538
331	08.10.2019	26164.0	A_{331}	0.8959	C_{117}	A_{331}	0.8959
332	09.10.2019	26346.0	A_{332}	0.9321	C_{125}	$A_{204} \cap A_{332}$	0.9320
333	10.10.2019	26496.7	A_{333}	0.9534	C_{131}	$A_{71} \cap A_{80} \cap A_{285} \cap A_{330} \cap A_{333}$	0.9538

Оценивая показатели индекса ДЛИА по средствам критериев C_k ($k=1\div 144$), детализация которых представлена в Таблице 2, в рамках нечеткого временного ряда индекса ДЛИА выявлены внутренние связи 1-го порядка в виде нечеткий отношений, которые разбиты на 144 группы и сведены в Таблицу 4.

Таблица 4. Внутренние связи 1-го порядка, разбитые по группам

Символ	Группа	Символ	Группа
G ₁	C ₁ ⇒ C ₁ , C ₄	G ₁₃₆	C ₁₃₆ ⇒ C ₁₃₀ , C ₁₄₁
G ₂	C ₂ ⇒ C ₁₀	G ₁₃₇	C ₁₃₇ ⇒ C ₁₃₅ , C ₁₄₀
G ₃	C ₃ ⇒ C ₁	G ₁₃₈	C ₁₃₈ ⇒ C ₁₃₉ , C ₁₄₁
G ₄	C ₄ ⇒ C ₆	G ₁₃₉	C ₁₃₉ ⇒ C ₁₃₃ , C ₁₃₈ , C ₁₃₉ , C ₁₄₁ , C ₁₄₂
G ₅	C ₅ ⇒ C ₈	G ₁₄₀	C ₁₄₀ ⇒ C ₁₃₄ , C ₁₃₉
G ₆	C ₆ ⇒ C ₅	G ₁₄₁	C ₁₄₁ ⇒ C ₁₄₂ , C ₁₄₃ , C ₁₄₄
G ₇	C ₇ ⇒ C ₃	G ₁₄₂	C ₁₄₂ ⇒ C ₁₃₆ , C ₁₄₁ , C ₁₄₂ , C ₁₄₃ , C ₁₄₄
G ₈	C ₈ ⇒ C ₉	G ₁₄₃	C ₁₄₃ ⇒ C ₁₃₄ , C ₁₃₈ , C ₁₄₂ , C ₁₄₃ , C ₁₄₄
...		G ₁₄₄	C ₁₄₄ ⇒ C ₁₃₄ , C ₁₃₉ , C ₁₄₂ , C ₁₄₃ , C ₁₄₄

Внутренние связи 1-го порядка представляют собой нечеткие отношения, отражающие причинно-следственные связи между качественными (нечеткими) оценками исторических показателей индекса DJIA, как термов соответствующих лингвистических переменных, и их нечеткими прогнозами. Данную связь однозначно отражает импликативное правило вида:

«Если x_t есть C_i , то x_{t+1} есть C_j » ($t=1÷333$; $i, j=1÷144$),

и неоднозначно отражает импликативное правило вида:

«Если x_t есть C_i , то x_{t+1} есть $C_{j(1)}$ или $C_{j(2)}$ или ... или $C_{j(p)}$ » ($t=1÷333$; $i, j(1), j(2), \dots, j(p)=1÷144$).

Если в случае 1-ой импликации все предельно ясно, то при наличии двух и более альтернативных нечетких выводов агрегация нечеткого прогноза осуществляется с применением логического оператора «или». В частности, для нечетких отношений: $C_{36} \Rightarrow C_{21}$, C_{51} , C_{52} нечеткий прогноз отражается нечетким множеством $F=C_{21} \cup C_{51} \cup C_{52}$ с функцией принадлежности

$$\mu_F(u) = \mu_{C_{21} \cup C_{51} \cup C_{52}}(u) = \max \{ \mu_{C_{21}}(u), \mu_{C_{51}}(u), \mu_{C_{52}}(u) \}.$$

В Таблице 5 представлены прогнозы, отражающие следствия в группах внутренних связей 1-го порядка. В нотации ТО НМ прогностическая модель нечеткого временного ряда DJIA, построенная на основе анализа внутренних связей 1-го порядка, индуцирует дефаззифицированные выходы (прогнозы) в

масштабе отрезка $[0, 1]$, которые сведены в Таблицу 6. Геометрическая интерпретация прогностической модели 1-го порядка в сравнении с временным рядом DJIA в нотации ТО НМ показана на Рис. 4.

Таблица 5. Нечёткие выводы, как следствия в группах G_k ($k=1+144$)

Нечеткий прогноз	Значения функции принадлежности							ТО НМ
	0	0.1	0.2	0.3	...	0.9	1	
F_1	0.9138	0.2051	0.2051	0.2051	...	0.0412	0.0412	0.0767
F_2	0.5875	0.4978	0.4978	0.4978	...	0.1492	0.0031	0.2758
F_3	0.9138	0.0412	0.0412	0.0412	...	0.0412	0.0412	0.0226
F_4	0.7193	0.3392	0.3392	0.3392	...	0.0496	0.0396	0.1491
.....								
F_{141}	0.0147	0.0147	0.0147	0.0147	...	0.0147	0.9423	0.9922
F_{142}	0.0369	0.0469	0.0532	0.0532	...	0.0532	0.9423	0.9730
F_{143}	0.0422	0.0422	0.0625	0.0737	...	0.0737	0.9800	0.9662
F_{144}	0.0337	0.0337	0.0625	0.0737	...	0.0737	0.9423	0.9657

Таблица 6. Прогностическая модель временного ряда DJIA

Дата	Нечеткий аналог индекса		Кр.	Группа связей 1-го порядка	Выход модели (прогноз)		Детализация нечеткого выхода
	Smb.	ТО			Smb.	ТО	
15.06.2018	A_1	0.6062	C_{55}	$C_{55} \Rightarrow C_{51}, C_{54}, C_{59}$	—	—	
18.06.2018	A_2	0.5939	C_{51}	$C_{51} \Rightarrow C_{40}, C_{41}$	F_{55}	0.6203	$C_{51} \cup C_{54} \cup C_{59}$
19.06.2018	A_3	0.5330	C_{41}	$C_{41} \Rightarrow C_{28}, C_{39}, C_{49}$	F_{51}	0.5318	$C_{40} \cup C_{41}$
20.06.2018	A_4	0.5219	C_{39}	$C_{39} \Rightarrow C_{32}$	F_{41}	0.4557	$C_{28} \cup C_{39} \cup C_{49}$
.....							
07.10.2019	A_{330}	0.9513	C_{131}	$C_{131} \Rightarrow C_{81}, C_{117}, C_{127}, C_{129}$	F_{134}	0.8944	$C_{111} \cup C_{131} \cup C_{132}$
08.10.2019	A_{331}	0.8959	C_{117}	$C_{117} \Rightarrow C_{125}$	F_{131}	0.8127	$C_{81} \cup C_{117} \cup C_{127} \cup C_{129}$
09.10.2019	A_{332}	0.9321	C_{125}	$C_{125} \Rightarrow C_{116}, C_{131}$	F_{117}	0.9320	C_{125}
10.10.2019	A_{333}	0.9534	C_{131}	$C_{131} \Rightarrow C_{81}, C_{117}, C_{127}, C_{129}$	F_{125}	0.9055	$C_{116} \cup C_{131}$
MSE						0.0020	
MAPE						4.4879	
MPE						-0.4391	

В Таблице 6 приведены значения известных статистических критериев оценки: MSE (Mean Squared Error), MAPE (Mean Absolute Percentage Error) и MPE (Mean Percentage Error), которые отражают адекватность предлагаемой прогностической модели. MSE наиболее часто применяется для выбора оптимальной модели прогнозирования и указывает на возможные

существенные ошибки. В рассматриваемом случае $MSE=0.0020$ подчеркивает чересчур низкую погрешность в предлагаемом методе прогнозирования. $MARE$ демонстрирует насколько существенно отклонение прогноза относительно соответствующего актуального значения временного ряда. MPE является более информативным критерием для оценки адекватности модели прогнозирования. Он определяет так называемую «смещённость» предлагаемого прогноза, то есть его постоянное занижение или завышение. В данном случае $MPE=-0.4391\%$ отражает незначительную *смещённость* модели, т.к. не превышает нормативный порог слева в 5% .



Рис. 4. Прогностическая модель 1-го порядка в нотации ТО НМ

Для окончательного решения задачи актуальные и прогнозируемые выходы построенной модели необходимо отобразить в номинальных величинах. С этой целью используется трехслойная нейронная сеть предложенной топологии в виде результативного компилятора правил прогнозирования нечетких тенденций, выраженных в виде дефаззифицированных значений нечетких интерпретаций исторических данных. Для построения и адаптации аппроксимационной нейронной сети выберем за основу множество обучающих пар $\{(A_t^{\text{def}}, x_t)\}_{t=1}^{136}$, где x_t — исторический показатель DJIA на момент времени t ; A_t^{def} — дефаззифицированное значение (или точечная оценка) нечёткого множества A_t ,

отражающего показатель x_t . После выполнения процессов обучения, тестирования и валидации нейронная сеть аппроксимирует непрерывную функцию $x_t=f(A_t^{\text{def}})$, представленной в виде Таблицы 7.

После аппроксимации функции $x_t=f(A_t^{\text{def}})$ обученная нейронная сеть индуцирует на своём выходе номинальные прогнозные значения для временного ряда индекса DJIA, которые соответствуют соответствующим дефазифицированным значениям нечётких выходов, представленным в Таблице 7. Полученные прогнозы сведены в Таблицу 8, а сама модель нечеткого временного ряда интерпретирована на Рис. 5 на фоне исходного ряда DJIA.

Таблица 7. Табличное представление функции $x_t=f(A_t^{\text{def}})$

t	A_t^{def}	x_t	t	A_t^{def}	x_t	t	A_t^{def}	x_t	t	A_t^{def}	x_t
1	0.6062	25090.5	35	0.6392	25462.6	69	0.9835	26743.5	132	0.0226	22445.4
2	0.5939	24987.5	36	0.6467	25502.2	70	0.9615	26562.1	133	0.0216	21792.2
3	0.5330	24700.2	37	0.6736	25628.9	71	0.9529	26492.2	134	0.0821	22878.5
4	0.5219	24657.8	38	0.6614	25583.8	72	0.9384	26385.3	135	0.1491	23138.8
***	***	***	***	***	***	***	***	***	136	0.1257	23062.4

Таблица 8. Прогнозирование временного ряда DJIA

№	Дата	DJIA	Прогноз	№	Дата	DJIA	Прогноз
1	15.06.2018	25090.5		323	26.09.2019	26891.1	26598
2	18.06.2018	24987.5	25299	324	27.09.2019	26820.3	26598
3	19.06.2018	24700.2	24694	325	30.09.2019	26916.8	26661
4	20.06.2018	24657.8	24400	326	01.10.2019	26573.0	26598
5	21.06.2018	24461.7	24463	327	02.10.2019	26078.6	26157
6	22.06.2018	24580.9	24396	328	03.10.2019	26201.0	26129
7	25.06.2018	24252.8	24664	329	04.10.2019	26573.7	26093
8	26.06.2018	24283.1	24285	330	07.10.2019	26478.0	26157
9	27.06.2018	24117.6	24291	331	08.10.2019	26164.0	25895
10	28.06.2018	24216.1	23537	332	09.10.2019	26346.0	26342
***	***	***	***	333	10.10.2019	26496.7	26204
MSE							72100.5
MAPE							0.6830
MPE							-0.2530



Рис. 5. Прогностическая модель в номинальных значениях

В Таблице 8 приведены значения показателей $MSE = 72100.5$, $MAPE = 0.6830$ и $MPE = -0.2530$, которые отражают адекватность предлагаемой прогностической модели в номинальных значениях индекса DJIA. В частности, величина MSE указывает на достаточно большую погрешность в прогнозировании, что мы объясняем недостаточно удовлетворительным качеством обучения нейронной сети ($\varepsilon = 19.4803$). При этом, MAPE демонстрирует достаточно приемлемую величину ошибки прогноза в сравнении с актуальными значениями временного ряда индекса DJIA. При этом, MPE, как более информативный критерий оценки, отражает незначительную «смещённость» прогностической модели, не превышающую нормативного 5%-го порога слева.

Сравнивая по качеству две предложенные модели, нетрудно заметить, что прогностическая модель временного ряда в номинальных величинах индекса DJIA существенно уступает прогностической модели в терминах точечных оценок соответствующих нечетких множеств. Применяя прогностическую модель в терминах точечных оценок, в качестве прогноза индекса DJIA на 334-й день получим число $A_i^{def} = 0.8127$, что является ТО нечеткого прогноза $F_{131} = C_{81} \cup C_{117} \cup C_{127} \cup C_{129}$. Этот прогноз нейронная сеть интерпретирует в виде номинальной величины как 26204.

В третьей главе предлагается метод компиляции знаний о внутренних нечетких закономерностях с применением тривиальной (с одним линейным скрытым слоем) и многослойной нейронных сетей. Проводится анализ и прогнозирование волатильного временного ряда в парадигме «глубокого обучения», т.е. с применением нейро-сетевых моделей. В целях прогнозирования временных рядов рассматриваются различные нейро-сетевые топологии и их сравнительный анализ на примере прогнозирования волатильного временного ряда индекса DJIA с применением среднестатистических критериев оценки.

На Рис. 6 фигурально представлена нейронная сеть, состоящая из входного, скрытого и выходного слоев. Путем активации функции *newff* сеть формируется в нотации пакета MATLAB, подразумевающая 10 входов (10 отсроченных значений индекса DJIA) и один выход, как последующее значение индекса DJIA.




Рис. 6. Фигуральное представление трехслойной нейронной сети

На базе исторических показателей временного ряда индекса DJIA построено множество обучающих пар в виде:

$\{x(t-10), x(t-9), \dots, x(t-1)\} \rightarrow x(t), t = 1 \div 333,$
 которые сведены в Таблицу 9.

Таблица 9. Множество обучающих пар для проектирования нейронной сети

t	Входы нейро-сетевой модели							Желаемый выход
	$x(t-10)$	$x(t-9)$	$x(t-8)$	...	$x(t-3)$	$x(t-2)$	$x(t-1)$	$x(t)$
11	25090.5	24987.5	24700.2	...	24283.1	24117.6	24216.1	24271.4
12	24987.5	24700.2	24657.8	...	24117.6	24216.1	24271.4	24307.2
13	24700.2	24657.8	24461.7	...	24216.1	24271.4	24307.2	24174.8
14	24657.8	24461.7	24580.9	...	24271.4	24307.2	24174.8	24356.7
15	24461.7	24580.9	24252.8	...	24307.2	24174.8	24356.7	24456.5
.....								
329	26935.1	26950.0	26807.8	...	26573.0	26078.6	26201.0	26573.7
330	26950.0	26807.8	26970.7	...	26078.6	26201.0	26573.7	26478.0
331	26807.8	26970.7	26891.1	...	26201.0	26573.7	26478.0	26164.0
332	26970.7	26891.1	26820.3	...	26573.7	26478.0	26164.0	26346.0
333	26891.1	26820.3	26916.8	...	26478.0	26164.0	26346.0	26496.7

После обучения, тестирования и валидации инициированная нейронная сеть FFNN восстановила временной ряд индекса DJIA в достаточно приемлемом виде, представленным на Рис. 7, а. Данные $x(t)$ восстановленного нейронной сетью временного ряда индекса DJIA, сведены в Таблицу 10, а зависимость ошибки при восстановлении временного ряда нейронной сетью от числа итераций представлена на Рис. 7, б.




Рис. 7. Нейронное прогнозирование временного ряда индекса DJIA: а) восстановление временного ряда, б) зависимость ошибки от числа итерации

Таблица 10. Нейро-сетевое моделирование временного ряда индекса DJIA

Дата	FFNN	Дата	FFNN	Дата	FFNN	Дата	FFNN
15.06.18	×	23.11.18	24328	08.05.19	25979	18.09.19	27146
18.06.18	×	26.11.18	24175	09.05.19	26025	19.09.19	27043
19.06.18	×	27.11.18	24758	10.05.19	25838	20.09.19	26962
20.06.18	×	28.11.18	24851	13.05.19	26012	23.09.19	26844
21.06.18	×	29.11.18	25500	14.05.19	25482	24.09.19	26915
22.06.18	×	30.11.18	25333	15.05.19	25702	25.09.19	26688
25.06.18	×	03.12.18	25611	16.05.19	25681	26.09.19	26819
26.06.18	×	04.12.18	25706	17.05.19	26037	27.09.19	26696
27.06.18	×	06.12.18	25026	20.05.19	25801	30.09.19	26693
28.06.18	×	07.12.18	24805	21.05.19	25864	01.10.19	26770
29.06.18	24153	10.12.18	24339	22.05.19	25784	02.10.19	26485
02.07.18	24222	11.12.18	24394	23.05.19	25892	03.10.19	26042
03.07.18	24313	12.12.18	24489	24.05.19	25541	04.10.19	26238
05.07.18	24109	13.12.18	24648	28.05.19	25650	07.10.19	26508
06.07.18	24352	14.12.18	24514	29.05.19	25345	08.10.19	26410
09.07.18	24414	17.12.18	23957	30.05.19	25207	09.10.19	26250
...	...	...	...	...	...	10.10.19	26365

Для оценки адекватности и сравнения рассмотренных выше нейро-сетевых подходов к прогнозированию волатильных временных рядов на основе выбранного временного ряда индекс DJIA воспользуемся статистическими критериями оценки MSE, MAPE и MPE. Результаты сравнения с применением приведенных критериев оценки приведены в следующей Таблице 11, а геометрическая интерпретация результатов представлена Рис. 8.

Таблица 11. Результаты прогнозирования временного ряда индекса DJIA

Дата	Индекс DJIA	Нейронные сети		Дата	Индекс DJIA	Нейронные сети	
		LNN	FFNN			LNN	FFNN
15.06.18	25090.5	17389	×	18.09.19	27147.1	26164	27146
18.06.18	24987.5	25226	×	19.09.19	27094.8	26183	27043
19.06.18	24700.2	24955	×	20.09.19	26935.1	26171	26962
20.06.18	24657.8	24910	×	23.09.19	26950.0	26120	26844
21.06.18	24461.7	24680	×	24.09.19	26807.8	26132	26915
22.06.18	24580.9	24784	×	25.09.19	26970.7	26093	26688
25.06.18	24252.8	24465	×	26.09.19	26891.1	26149	26819
26.06.18	24283.1	24554	×	27.09.19	26820.3	26122	26696

27.06.18	24117.6	24367	×	30.09.19	26916.8	26100	26693
28.06.18	24216.1	24512	×	01.10.19	26573.0	26128	26770
29.06.18	24271.4	25277	24153	02.10.19	26078.6	26026	26485
02.07.18	24307.2	25283	24222	03.10.19	26201.0	25868	26042
03.07.18	24174.8	25294	24313	04.10.19	26573.7	25909	26238
05.07.18	24356.7	25243	24109	07.10.19	26478.0	26025	26508
06.07.18	24456.5	25302	24352	08.10.19	26164.0	25990	26410
09.07.18	24776.6	25329	24414	09.10.19	26346.0	25899	26250
11.07.18	24700.5	25460	24987	10.10.19	26496.7	25957	26365
12.07.18	24924.9	25389	24754		MSE	616507	54170
13.07.18	25019.4	25459	24906		MAPE	2.0913	0.6608
***	***	***	***		MPE	0.0970	0.0138



Рис. 8. Геометрическая интерпретация моделей временного ряда DJIA

В рассматриваемом примере показатели $MSE_{LNN} = 616507$ и $MSE_{FFNN} = 54170$ подчеркивают чересчур высокие погрешности при применении обоих видов нейронных сетей для прогнозирования временного ряда. Тем не менее, погрешность от применения трехслойной нейронной сети более чем на порядок меньше, чем среднеквадратичное отклонение выходов модели временного ряда индекса DJIA, построенной с применением сети LNN.

Показатели $MAPE_{LNN} = 2.0913$ и $MAPE_{FFNN} = 0.6608$ демонстрируют незначительное отклонение прогноза относительно соответствующего актуального значения

временного ряда. Показатели $MPE_{LNN} = 0.0970$ и $MPE_{FFNN} = 0.0138$ демонстрируют незначительные «смещённости» предлагаемых моделей. Оба показателя не превышают нормативный порог справа в 5%. При этом значение этого показателя для модели с применением трехслойной нейронной сети существенно ниже, что также указывает ее предпочтительность с точки зрения точности прогнозирования временного ряда индекса DJIA.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ

Основные научные результаты, выносимые на защиту, сформулированы в виде следующих утверждений:

- Временной ряд нечетких закономерностей является эффективным индикатором волатильного развития моделируемого процесса на фондовой бирже, который описан в качественных категориях по средствам термов лингвистических переменных.
- Ключевыми операциями обработки нечетких закономерностей являются алгоритмы обработки внутренних нечетких связей, а именно, методика восстановления нечеткого временного ряда по исходному временному ряду и обратная операция компиляции временного ряда в номинальных величинах, как отражение идентифицированных нечетких тенденций.
- Трехслойная нейронная сеть предложенной топологии является результативным компилятором правил прогнозирования нечетких тенденций, выраженных в виде дефазсифицированных значений нечетких интерпретаций исторических данных.
- Разработанная прогностическая модель на основе временных рядов нечетких тенденций позволяет прогнозировать волатильный временной ряд на краткосрочный период.
- Разработанная нейро-сетевая модель выбранной топологии позволяет прогнозировать волатильный временной ряд на краткосрочный период.

**Основные результаты диссертационной работы
опубликованы в следующих научных статьях:**

1. Марданов М. Дж., Рзаев Р.Р., Ализаде П.Э. Об одном подходе к фаззификации данных на примере временного ряда индекса Доу-Джонса. Математические Машины и Системы, Институт Проблем Математических Машин и Систем, Киев, 2020, №2, стр. 3–13. (БАК Украины)
2. Mardanov M.J., Rzayev R.R., Alizada P.E. About one approach to modeling and forecasting the fuzzy time series. Proceeding of the 7th International Conference on Control and Optimization with Industrial Applications, COIA – 2020, Vol. 1, pp. 269–271, Baku, 26–28 August 2020.
3. Alizada P.E., Mehdiyev T.Z. One approach to volatile time series forecasting. Advances in Intelligent Systems and Computing, Vol. 1306, pp. 433–441, 2021 (indexed by WoS and Scopus).
4. Alizada P.E. Conversion of volatile time series into a fuzzy time series by the example of the Dow Jones index dynamics. Lecture Notes in Networks and Systems, Vol. 362, pp.662–670, 2022 (indexed by WoS and Scopus).
5. Abdullayev Kh.Kh., Alizada P.E., Salmanli F.M. Fuzzy time series forecasting by the example of the Dow Jones Index dynamics. Lecture Notes in Networks and Systems, Vol. 438, pp. 216–228, 2022 (indexed by WoS and Scopus).
6. Rzayev R.R., Alizada P.E. Dow Jones index time series forecasting using feedforward neural network model. Springer Series: Recent Developments and the New Directions of Research, Foundations, and Applications, Vol. 1, pp. 329–337, 2023 (indexed by WoS and Scopus).
7. Рзаев Р.Р., Ализаде П.Э., Мехтиев Т.З. Об одном подходе к прогнозированию нечетких временных рядов на примере динамики изменения индекса Доу Джонса – Часть I. Proceedings of IAM, V. 11, №2, 2022, pp. 87–102.
8. Рзаев Р.Р., Ализаде П.Э., Мехтиев Т.З. Об одном подходе к прогнозированию нечетких временных рядов на примере динамики изменения индекса Доу Джонса – Часть II. Proceedings of IAM, V.12, №1, 2023, pp. 3–14.

9. Rzayev R.R., Alizada P.E., Mehdiyev T.Z. Volatile time series forecasting on the example of the dynamics of the Dow Jones index. Problems of information society, 2023, Vol.14, №1, pp. 14–25.
10. Rzayev R.R., Alizada P.E., Mehdiyev T.Z. Fuzzy time series forecasting on the example of the Dow Jones index dynamics. Springer series “Lecture Notes in Networks and Systems”, Vol. 438, pp. 216-228.

Личный вклад соискателя в трудах, опубликованных в соавторстве:

- [1] Определение универсума, как покрытия исторических данных временного ряда индекса Доу-Джонса, формирование совокупности качественных критериев оценки и установление внутренних связей 1-го порядка, отражающих причинно-следственные связи между историческими данными.
- [2] Проведение расчетов, связанных с дефаззификацией нечетких выходов прогностической модели временного ряда индекса Доу-Джонса.
- [3] Фаззификация исторических данных, формирование оптимальной совокупности качественных критериев оценки и построение прогностической модели 1-го порядка для временного ряда индекса Доу-Джонса.
- [5] Анализ исторических данных на предмет волатильности, фаззификация исторических данных с применением Гауссовской функции принадлежности, построение прогностической модели и ее оценка на адекватность.
- [6] Проведение симуляций в программной оболочке Neural Networks Toolbox пакета прикладных программ MATLAB на предмет нейронной аппроксимации зависимостей внутри волатильного временного ряда индекса Доу-Джонса.
- [7] Адаптация системы нечёткого вывода для фаззификации исторических данных с применением функций принадлежности Гауссовского типа.
- [8] Прогнозирование временного ряда индекса Доу-Джонса в терминах точечных оценок нечетких выходов

прогностической модели, а также в номинальных величинах индекса Доу-Джонса посредством нейронной аппроксимации непрерывной функции от дефаззифицированных значений нечетких выходов модели.

- [9] Разработка правил фаззификации исторических данных и дефаззификации нечетких прогнозов временного ряда.
- [10] Построение прогностической модели для прогнозирования временного ряда индекса Доу-Джонса на основе выявления внутренних связей 1-го порядка.

Защита диссертации состоится 10.09.2024 г. в 14:00 на заседании Диссертационного Совета ЕД 2.48 при Азербайджанском Государственном Университете Нефти и Промышленности.

Адрес: Баку, пр. Азадлыг, 20 AZ1010.

С диссертационной работой можно ознакомиться в библиотеке Азербайджанского Государственного Университета Нефти и Промышленности.

Электронная версия диссертации и автореферата размещена на официальном сайте Азербайджанского Государственного Университета Нефти и Промышленности.

Автореферат разослан соответствующим адресам
05.08.2024-го года.

Подписано в печать: 28.06.2024

Формат бумаги: А5

Объем: 37 089

Тираж: 100