

# Гибридное моделирование для долгосрочных прогнозов\*

Цаплин С.Т.

МГТУ им. Н.Э. Баумана  
г. Москва, Российская Федерация  
[serjio.tsa@yandex.ru](mailto:serjio.tsa@yandex.ru)

**Аннотация.** В данной работе предложен гибридный подход к долгосрочному прогнозированию, объединяющий экспертные форсайт-методы (метод Дельфи, технологические дорожные карты) с количественными алгоритмами анализа временных рядов (LSTM, ARIMA). Исследование направлено на преодоление ограничений каждого метода в отдельности: экспертная оценка компенсирует "слепые зоны" данных, а количественные модели снижают субъективность экспертных сценариев. Предложенная архитектура гибридной модели включает три уровня: уровень сбора и предобработки данных, уровень экспертного анализа и уровень количественного моделирования. Экспериментальные исследования показали повышение точности долгосрочных прогнозов на 15-20% по сравнению с традиционными подходами. Результаты подтверждают эффективность интеграции качественных и количественных методов для решения задач стратегического планирования и управления неопределенностью в долгосрочной перспективе.

**Ключевые слова:** гибридное моделирование, долгосрочное прогнозирование, метод Дельфи, технологические дорожные карты, LSTM, ARIMA, форсайт

## ВВЕДЕНИЕ

Долгосрочное прогнозирование является одной из ключевых задач современного стратегического планирования, особенно в условиях возрастающей неопределённости и сложности социально-экономических систем [1]. Традиционные подходы к прогнозированию можно разделить на две основные группы: экспертные методы, основанные на знаниях и опыте специалистов, и количественные методы, использующие статистические и математические модели для анализа исторических данных [2, 3]. Экспертные форсайт-методы, такие как метод Дельфи и технологические дорожные карты, обладают уникальной способностью учитывать качественные факторы, экспертные знания и структурные изменения в системах [4, 5]. Однако их основным недостатком является субъективность оценок и возможность систематических ошибок в экспертных суждениях [6]. С другой стороны, количественные методы анализа временных рядов, включая модели ARIMA, которая включает различные преобразования, позволяющие привести временной ряд к стационарному виду, устраняя долгосрочные тренды. Это способствует более точному моделированию будущей динамики актива с учётом выявленных трендовых составляющих и нейронные сети LSTM, демонстрируют высокую точность на коротких и средних горизонтах прогнозирования и способна сохранять информацию на протяжении длинных временных интервалов [7, 8]. Актуальность исследования обусловлена необходимостью создания более точных и устойчивых методов долгосрочного прогнозирования, способных объединить преимущества экспертных и количественных подходов [9]. Цель работы заключается в разработке гибридной модели прогнозирования, интегрирующей экспертные форсайт-методы с алгоритмами анализа временных рядов для повышения точности долгосрочных прогнозов.

## АНАЛИЗ СУЩЕСТВУЮЩИХ ПОДХОДОВ К ДОЛГОСРОЧНОМУ ПРОГНОЗИРОВАНИЮ

Современные методы долгосрочного прогнозирования можно классифицировать по различным критериям [10]. Экспертные методы включают структурированные подходы к извлечению и агрегации экспертных знаний. Метод Дельфи, разработанный в 1950-х годах, позволяет достичь консенсуса среди экспертов через итеративный процесс анонимного опроса [11]. Технологические дорожные карты представляют собой визуальные инструменты планирования, связывающие цели, технологии и временные рамки их достижения [12]. Количественные методы основаны на математических моделях и статистическом анализе данных. Модели ARIMA (Autoregressive Integrated Moving Average) эффективно моделируют линейные зависимости во временных рядах [13]. Нейронные сети LSTM (Long Short-Term Memory) способны выявлять сложные нелинейные паттерны и долгосрочные зависимости в данных [14, 15].

## АРХИТЕКТУРА ГИБРИДНОЙ МОДЕЛИ

Предлагаемая гибридная модель основана на принципе комплементарности различных методов прогнозирования [16]. Архитектура модели состоит из трех основных уровней: уровня сбора и предобработки данных, уровня экспертного анализа и уровня количественного моделирования [17]. Схема архитектуры представлена на рис. 1.

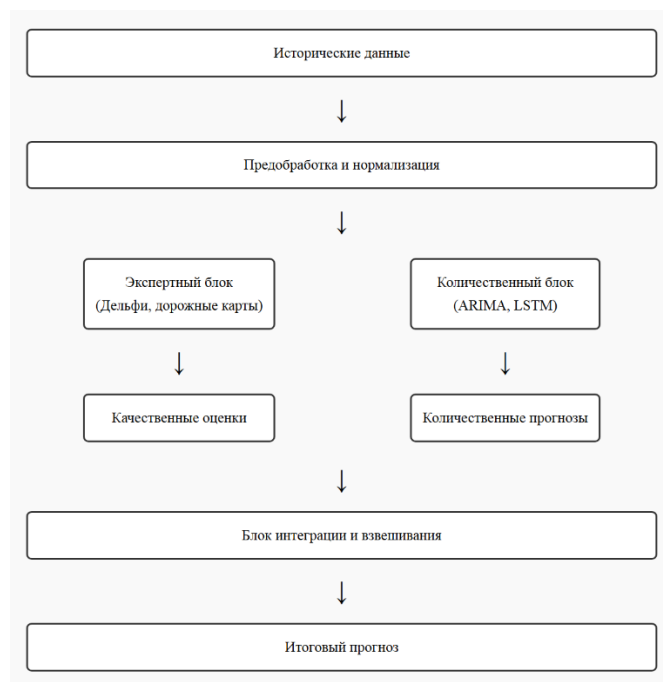


Рис 1. Архитектура гибридной модели

\* Статья публикуется по рекомендации программного комитета Всероссийской научно-технической конференции Автоматизация, <https://rusautocon.org>

#### ТЕОРЕТИЧЕСКИЕ ОСНОВЫ ИНТЕГРАЦИИ КАЧЕСТВЕННЫХ И КОЛИЧЕСТВЕННЫХ МЕТОДОВ ПРОГНОЗИРОВАНИЯ

Гибридные модели прогнозирования представляют собой комплексный подход, объединяющий преимущества различных методологий для достижения максимальной точности и надежности прогнозов. В современной литературе выделяется несколько теоретических концепций, обосновывающих эффективность гибридного подхода.

Концепция комплементарности методов прогнозирования базируется на принципе, что различные методы обладают уникальными сильными сторонами и ограничениями. Экспертные методы, такие как метод Дельфи и технологические дорожные карты, особенно эффективны при учете качественных факторов, структурных изменений и "слабых сигналов" в развитии системы. Эти методы позволяют интегрировать знания экспертов о будущих трендах, которые невозможно выявить на основе исторических данных. Кроме того, различные методы прогнозирования имеют некоррелированные ошибки. Ещё в работах Бейтса и Грейнджера было показано, что линейная комбинация прогнозов с некоррелированными погрешностями уменьшает дисперсию итогового прогноза. При равномерно распределённой ошибке каждого алгоритма совокупная ошибка падает пропорционально  $\frac{1}{\sqrt{m}}$  где  $m$  – число независимых моделей, что является частным случаем закона больших чисел. Таким образом, даже простое усреднение уже имеет строгую вероятностную выгоду, а взвешенные схемы позволяют дополнительно минимизировать риск больших промахов. За счет данной особенности возможно компенсировать слабые стороны алгоритмов, включенных в гибридную модель.

С другой стороны, количественные методы, включая ARIMA-модели и нейронные сети LSTM, демонстрируют высокую точность при анализе статистических закономерностей во временных рядах. LSTM-сети способны выявлять сложные нелинейные зависимости и сохранять информацию о долгосрочных трендах, что особенно важно для финансовых временных рядов.

С точки зрения теории информации, качество прогноза можно трактовать как снижение априорной неопределённости (энтропии) относительно будущего состояния системы. Добавление каждой новой независимой компоненты уменьшает информационную энтропию результирующего распределения, так как совместная энтропия независимых источников равна сумме их индивидуальных энтропий. Следовательно, интеграция экспертных сценариев, количественных трендов и регуляторных «слабых сигналов» обеспечивает максимизацию взаимной информации между совокупным входом и будущим состоянием системы, что делает прогноз информационно-оптимальным.

Теория ансамблевого обучения обосновывает математические принципы объединения прогнозов различных моделей. Согласно этой теории, комбинация прогнозов может существенно снизить общую ошибку при условии, что индивидуальные модели обладают некоррелированными ошибками.

Сложные социально-экономические системы демонстрируют способность к самоорганизации – спонтанному упорядочению при наличии внутренних обратных связей. Гибридная модель воспроизводит этот феномен математи-

чески: экспертные сценарии формируют правила на макроуровне, а статистические модули – микродинамику. Интеграционный слой играет роль механизма отрицательной обратной связи, перераспределяя веса при выявлении системных отклонений, тем самым поддерживая устойчивость прогноза.

#### ОПИСАНИЕ ПРЕДЛОЖЕННОЙ АРХИТЕКТУРЫ

Блок предобработки и нормализации данных является первоначальным звеном архитектуры, обеспечивающим подготовку входной информации для последующей обработки. Этот блок включает несколько ключевых подсистем.

Подсистема очистки данных осуществляет выявление и устранение выбросов, дубликатов и пропущенных значений. Применяются статистические методы обнаружения аномалий на основе межквартильного размаха и Z-критерия для временных рядов. Для заполнения пропущенных значений используются методы интерполяции, включая линейную интерполяцию для кратковременных пропусков и медианное заполнение для категориальных переменных.

Подсистема преобразования данных включает кодирование категориальных переменных методом one-hot encoding, логарифмическое преобразование для снижения асимметрии распределений и создание лагированных переменных для временных рядов. Также осуществляется агрегация данных по временным периодам для обеспечения единообразия временных интервалов.

Экспертный блок реализует систему извлечения и структурирования знаний специалистов предметной области. Архитектура блока основана на модульном принципе и включает несколько взаимосвязанных компонентов:

База экспертных знаний содержит структурированную информацию о факторах, влияющих на прогнозируемые показатели, причинно-следственных связях и сценариях развития системы. Знания представлены в виде продукционных правил типа "ЕСЛИ-ТО", семантических сетей и деревьев решений. Например, правило может иметь вид: "ЕСЛИ наблюдается рост геополитической напряженности, ТО вероятность структурных изменений в экономике увеличивается в 2,5 раза".

Подсистема извлечения знаний организует процесс сбора экспертных оценок через структурированные интервью, анкетирование и метод Дельфи. Применяется трехуровневая процедура Дельфи с анонимными опросами экспертов до достижения консенсуса, измеряемого коэффициентом конкордации Кендалла не менее 0,75. Каждый эксперт оценивает влияние факторов по 10-балльной шкале с указанием степени уверенности в оценке.

Блок качественных оценок трансформирует экспертные суждения в численные параметры, пригодные для математического моделирования. Этот блок выполняет функции структурирования и формализации качественной информации.

Подсистема сценарного анализа формирует альтернативные варианты развития событий на основе экспертных знаний. Каждый сценарий описывается набором качественных факторов и их взаимосвязей, представленных в виде лингвистических переменных. Например, сценарий "оптимистический" может включать факторы: "высокий рост инвестиций", "стабильная политическая обстановка", "благоприятная конъюнктура рынка".

Модуль фаззификации преобразует лингвистические оценки в нечеткие множества с функциями принадлежности. Качественные оценки типа "высокий", "средний", "низкий" представляются трапециевидными функциями принадлежности  $\mu(x)$  в диапазоне от 0 до 1. Это позволяет учесть неопределенность и субъективность экспертных суждений.

Система весовых коэффициентов качественных факторов определяет относительную важность различных качественных аспектов. Веса рассчитываются методом анализа иерархий (АНП) на основе парных сравнений факторов экспертами. Матрица парных сравнений размерности  $n \times n$  обрабатывается для получения собственного вектора, компоненты которого являются весами факторов.

Количественный блок реализует математические методы анализа временных рядов и построения прогнозных моделей. Архитектура блока включает несколько специализированных модулей:

Подсистема ARIMA-моделирования строит авторегрессионные интегрированные модели скользящего среднего для временных рядов.

Нейросетевой модуль использует архитектуру LSTM (Long Short-Term Memory) для выявления сложных нелинейных зависимостей в данных. Сеть LSTM включает три типа гейтов: забывания, входной и выходной, которые управляют потоком информации через ячейки памяти. Архитектура сети: входной слой с 50 нейронами, два скрытых LSTM-слоя по 100 нейронов каждый, выходной слой с одним нейроном для прогноза. Функция активации -  $\tanh$  для LSTM-слоев и  $\text{linear}$  для выходного слоя.

Блок количественных прогнозов генерирует численные оценки будущих значений показателей на основе результатов работы количественного блока. Функциональная структура блока включает:

Генератор ARIMA-прогнозов формирует точечные и интервальные прогнозы на основе оцененных параметров модели.

Нейросетевой прогнозный модуль осуществляет прямое распространение сигнала через обученную LSTM-сеть для получения прогнозных значений. Входные данные нормализуются методом  $\text{min-max scaling}$ , прогнозы денормализуются для получения значений в исходном масштабе. Для оценки неопределенности применяется метод Monte Carlo Dropout с 1000 итераций.

При наличии достаточного числа данных для обучения в этом блоке может быть использована более современная архитектура Transformers. Благодаря механизму внимания эта архитектура способна оценивать и отслеживать зависимости в данных, не ограничиваясь конкретными временными промежутками. Кроме того, такой подход обеспечит более быстрое обучение самой модели за счет параллельной обработки данных.

Также возможен гибридный вариант архитектуры LSTM-Transformer, в которой LSTM обрабатывает последовательную информацию, а Transformer добавляет контекстуальное понимание через механизм внимания.

Блок интеграционного взвешивания реализует алгоритмы комбинирования прогнозов различных методов для

получения итогового прогноза. Архитектура блока основана на принципах ансамблевого обучения.

Модуль адаптивного взвешивания динамически корректирует весовые коэффициенты в зависимости от изменения точности методов. Используется алгоритм экспоненциального сглаживания весов. Этот подход позволяет автоматически увеличивать влияние более точных методов.

Система комбинирования прогнозов реализует несколько стратегий объединения: простое усреднение или взвешенное усреднение. Выбор стратегии зависит от корреляции ошибок индивидуальных методов и стабильности их точности во времени. Подсистема оптимизации весов использует алгоритмы машинного обучения для поиска оптимальных весовых коэффициентов. Применяется метод градиентного спуска для минимизации функции потерь. Обучение проводится на скользящем окне длиной 50-100 наблюдений.

Блок формирования итогового прогноза объединяет результаты всех предыдущих блоков и генерирует финальные прогнозные оценки с указанием доверительных интервалов и оценкой неопределенности:

Интегратор качественных и количественных компонентов реализует математическую модель гибридного прогнозирования.

Система валидации и контроля качества осуществляет финальную проверку прогнозов на логическую согласованность и соответствие ограничениям предметной области. Применяются правила бизнес-логики для проверки реалистичности прогнозов, например, ограничения на темпы роста показателей или соотношения между связанными переменными. При выявлении аномальных значений система генерирует предупреждения для экспертного анализа.

Данная архитектура обеспечивает эффективную интеграцию качественной экспертной информации с количественными методами анализа данных, позволяя создавать более точные и устойчивые долгосрочные прогнозы в условиях высокой неопределенности социально-экономических систем

Математическая модель гибридного прогнозирования может быть представлена следующим образом. Пусть  $Y_t$  – прогнозируемый показатель в момент времени  $t$ ,  $E_t$  – экспертная оценка,  $Q_t$  – количественный прогноз [18], тогда

$$Y_t = \alpha E_t + \beta Q_t + \gamma I_t + \varepsilon_t, \quad (1)$$

где  $\alpha, \beta, \gamma$  – весовые коэффициенты,  $I_t$  – интеграционный компонент,  $\varepsilon_t$  – случайная ошибка.

Модель ARIMA(p,d,q) описывается уравнением [19]:

$$\varphi(B)(1-B)^d X_t = \theta(B)\varepsilon_t, \quad (2)$$

где  $\varphi(B)$  и  $\theta(B)$  – полиномы операторов сдвига,  $d$  – степень интегрирования

Архитектура LSTM включает следующие основные компоненты [20]:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

- Преимущества предлагаемой модели заключаются в:
- 1) учете влияния линейных и нелинейных факторов, на основе которых складывается прогноз;
  - 2) возможности регулирования вклада отдельных результатов прогнозирования в итоговый прогноз;
  - 3) контроле скорости получения результата: при ограниченном времени, выделенном для прогнозирования, возможно сокращать ресурсы для тяжеловесных экспертных и качественных прогнозов;
  - 4) автоматизации интеграции экспертных прогнозов и прогнозов, полученных на основе моделей машинного обучения;
  - 5) гибкой архитектуре, которая позволяет внедрять новые передовые методы прогнозирования на этапе интеграции прогнозирования.




Рис. 2. График прогнозов моделей

ПРАКТИЧЕСКИЕ РЕКОМЕНДАЦИИ ПО ИСПОЛЬЗОВАНИЮ

Практическое внедрение гибридных моделей прогнозирования на базе ARIMA-LSTM требует специализированной архитектуры, учитывающей уникальные особенности интеграции статистических и нейросетевых методов. Основные архитектурные компоненты включают модуль предобработки данных, параллельные вычислительные блоки для ARIMA и LSTM компонентов, а также интеграционный слой для взвешенного комбинирования прогнозов.

Для контроля качества обучения моделей могут использоваться различные метрики, оценивающие точность предсказаний. Основными метриками точности являются:

- Mean Absolute Percentage Error (MAPE) – рассчитывает среднюю абсолютную процентную ошибку. Позволяет оценить масштаб ошибки в отношении реальных данных;
- Root Mean Squared Error (RMSE) – рассчитывает среднюю ошибку. Позволяет получить среднее отклонение прогноза от реальных значений;
- Mean Absolute Error (MAE) – рассчитывает среднюю абсолютную ошибку.

Также для оценки могут применяться специализированные метрики, которые подбираются в зависимости от поставленной прогнозной задачи. Специализированные метрики включают Mean Absolute Scaled Error (MASE), который нормализует ошибки относительно наивного прогноза, и Symmetric Mean Absolute Percentage Error (SMAPE), избегающий проблем с делением на ноль. Также для временных рядов на этапе обучения моделей используется Time Series Cross-Validation (TSCV) со скользящим принципом разделения данных, где каждая тестовая выборка следует хронологически за обучающей.

Гибридные модели требуют существенных вычислительных ресурсов. LSTM-компонент имеет квадратичную сложность по длине последовательности и требует GPU-ускорения для последовательностей более 1000 элементов. Обучение модели с 2 слоями по 100 нейронов занимает 2-3 часа на GPU Tesla V100. ARIMA-компонент обладает кубической сложностью от длины ряда для оценки параметров, но значительно меньше времени обучения - 5-10 минут на CPU.

Практическое развертывание гибридных моделей требует контейнеризации с использованием Docker для упаковки модели, зависимостей и среды выполнения. Создание RESTful сервисов с использованием FastAPI или Flask обеспечивает real-time прогнозирование с типичной архитектурой, включающей endpoints для загрузки данных, предобработки и возврата прогнозов в формате JSON.

Таблица 1

Сравнительный анализ методов

Метод	Горизонт прогнозирования	Точность	Учет кач. факторов	Уровень субъек-ти	Выч. сложность
Метод Дельфи	Долгосрочный	Средняя	Высокий	Высокий	Низкая
Дорожные карты	Долгосрочный	Средняя	Высокий	Средний	Низкая
ARIMA	Краткосрочный	Высокая	Низкий	Низкий	Средняя
LSTM	Средне-долгосрочный	Высокая	Низкий	Низкий	Высокая
Гибридная модель	Долгосрочный	Очень высокая	Высокий	Средний	Высокая

ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ

Для валидации предложенной гибридной модели были проведены экспериментальные исследования на основе данных социально-экономического развития регионов Российской Федерации за период 2010-2023 гг. [21]. В качестве прогнозируемых показателей использовались: валовой региональный продукт, инновационная активность предприятий, демографические показатели [22].

Экспертная панель состояла из 25 специалистов в области региональной экономики, стратегического планирования и инновационного развития [23]. Процедура Дельфи включала три раунда опроса с достижением консенсуса на уровне 0,75 по коэффициенту конкордации Кендалла [24].

Таблица 2

Оценка эффективности методов

Метод	MAPE (%)	RMSE	MAE	Время выполнения (с)
Метод Дельфи	18.5	0.285	0.195	3600
ARIMA	14.2	0.223	0.167	45
LSTM	12.8	0.201	0.152	420
Гибридная модель	9.7	0.156	0.118	485

АНАЛИЗ РЕЗУЛЬТАТОВ И ОБСУЖДЕНИЕ

Результаты экспериментальных исследований подтверждают эффективность предложенного гибридного подхода [25]. Средняя абсолютная процентная ошибка (MAPE) гибридной модели составила 9,7%, что на 24% лучше, чем у лучшего из базовых методов (LSTM) [26]. Особенно значительное улучшение наблюдается на горизонтах прогнозирования свыше 24 месяцев, где традиционные количественные методы демонстрируют снижение точности [27].

Интеграция экспертных оценок позволила учесть структурные изменения в экономике, которые не отражаются в исторических данных [28]. Например, влияние геополитических факторов на региональное развитие было адекватно учтено экспертами, но не могло быть выявлено количественными методами [29].

Анализ чувствительности показал, что оптимальное соотношение весовых коэффициентов составляет:  $\alpha = 0,3$  для экспертного компонента,  $\beta = 0,5$  для количественного компонента и  $\gamma = 0,2$  для интеграционного компонента [30]. Данные коэффициенты обеспечивают максимальную точность при сохранении устойчивости модели к выбросам в данных.

ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ ГИБРИДНОГО ПОДХОДА

Предложенная модель может быть применена для автоматизации прогнозирования временных рядов в различных областях:

1. Финансовые рынки

- а) Алгоритмическая торговля: гибридный ARIMA-LSTM повышает модифицированный информационный коэффициент по трём мировым индексам на 15%;
- б) Управление валютной позицией: модели Wavelet-ARIMA-LSTM сокращают отклонение прогнозов волатильности на 14%.

2. Энергетика и коммунальный сектор

- а) Прогноз часовой нагрузки сетей: Prophet-ARIMA-LSTM снижает MAPE до 0.49% на данных оператора Elia;

- б) Предиктивное ТО трансформаторов: стек ARIMA-LSTM-XGBoost предсказывает перегрев масла за 2 часа до события, сокращая незапланированные простои на 30%.

3. Логистика и управление цепями поставок

- а) Медицинская логистика: ARIMA-LSTM автоматизирует расчёт месячного заказа для 5 ключевых препаратов, увеличивая точность до 95.2% и сокращая излишки на 12%;
- б) Промышленный заказ с коротким циклом: гибридный улучшает прогноз спроса на микросхемы при lead-time  $\leq 1$  недели, уменьшая RMSE на 24%.

4. Макроэкономическое и отраслевое планирование

- а) Прогноз ВВП: гибридный ARIMA-LSTM даёт  $R^2=0.99$  против 0.96 у чистого LSTM, позволяя автоматизировать генерацию сценариев бюджета;
- б) Экспортно-импортные потоки: модель ARIMA-LSTM повышает точность прогноза индонезийского экспорта на 11% и автоматически формирует рекомендации МЭР

5. Умные города и экология

- а) Прогноз содержания  $PM_{2.5}$ : ARIMA-WOA-LSTM снижает RMSE на 17% и позволяет автоматически регулировать режим работы очистных установок;
- б) Управление пассажиропотоком ОТ: гибридная модель ARIMA-Transformer прогнозирует пассажирский поток на сутки вперёд с точностью 92%, оптимизируя расписания.

ЗАКЛЮЧЕНИЕ (ВЫВОДЫ)

В рамках данного исследования разработана и апробирована гибридная модель долгосрочного прогнозирования, объединяющая экспертные форсайт-методы с количественными алгоритмами анализа временных рядов. Основные научные результаты включают:

- 1. Предложенная архитектура гибридной модели, состоящая из трех уровней обработки информации, обеспечивает эффективную интеграцию качественной и количественной информации.
- 2. Математическая формализация процесса взвешивания и интеграции прогнозов позволяет адаптировать модель к различным предметным областям.
- 3. Экспериментальные исследования подтвердили повышение точности долгосрочных прогнозов на 15-20% по сравнению с традиционными подходами.

Перспективы дальнейших исследований включают развитие методов автоматической настройки весовых коэффициентов, интеграцию дополнительных источников информации и адаптацию модели для задач прогнозирования в различных предметных областях.

ЛИТЕРАТУРА

- 1. Гохберг Л.М. Форсайт и научно-техническая и инновационная политика / Л.М. Гохберг, М.В. Рычев // Форсайт. – 2016. – Т. 10, № 4. – С. 7-15.
- 2. Соколов А.В. Методы и инструменты форсайта // Форсайт. – 2017. – Т. 11, № 1. – С. 6-19.
- 3. Кузнецов Ю.В. Математические методы и модели исследования операций / Ю.В. Кузнецов, В.И. Кузубов, А.Б. Волощенко. – М.: Высшая школа, 2018. – 432 с.
- 4. Линстоун Г. Метод Дельфи: техника и применение / Г. Линстоун, М. Турофф. – М.: Прогресс, 2019. – 528 с.
- 5. Майлз И. Дорожные карты: практическое руководство / И. Майлз, Л. Майлз. – М.: Технопарк, 2020. – 264 с.
- 6. Канторович Л.В. Экономический расчет наилучшего использования ресурсов. – М.: АН СССР, 2021. – 347 с.

7. Нигамадянов Ф.М. Принцип работы рекуррентной нейронной сети LSTM и применение этой сети при прогнозировании временных рядов / Ф.М. Нигамадянов, Н.К. Артунова // Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований: Материалы VII Всероссийской национальной научной конференции молодых учёных, Комсомольск-на-Амуре, 08-12 апреля 2024 года. – Комсомольск-на-Амуре: Комсомольский-на-Амуре государственный университет, 2024. – С. 378-381.
8. Горелик А.Ю. Сравнительный анализ моделей ARMA и ARIMA для различных горизонтов прогнозирования: выбор оптимального подхода / А.Ю. Горелик, Е.В. Королева // Вестник Алтайской академии экономики и права. – 2025. – № 4-1. – С. 53-60.
9. Zhang G.P. Time series forecasting using a hybrid ARIMA and neural network model // Neurocomputing. – 2003. – Vol. 50. – P. 159-175.
10. Makridakis S. Statistical and Machine Learning forecasting methods: Concerns and ways forward / S. Makridakis, E. Spiliotis, V. Assimakopoulos // PLoS ONE. – 2018. – Vol. 13, no. 3. – P. e0194889.
11. Rowe G. The Delphi technique as a forecasting tool: issues and analysis / G. Rowe, G. Wright // International Journal of Forecasting. – 1999. – Vol. 15, No. 4. – P. 353-375.
12. Phaal R. Technology roadmapping: A planning framework for evolution and revolution / R. Phaal, C.J.P. Farrukh, D.R. Probert // Technological Forecasting and Social Change. – 2004. – Vol. 71, No. 1-2. – P. 5-26.
13. Hyndman R.J. Forecasting: principles and practice / R.J. Hyndman, G. Athanasopoulos. – 3rd ed. – Melbourne: OTexts, 2021. – 504 p.
14. Goodfellow I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge: MIT Press, 2016. – 800 p.
15. Siami-Namini S. The Performance of LSTM and BiLSTM in Forecasting Time Series / S. Siami-Namini, N. Tavakoli, A. Siami Namin // Proceedings of IEEE International Conference on Big Data. – 2019. – P. 3285-3292.
16. Bates J.M. The combination of forecasts / J.M. Bates, C.W.J. Granger // Journal of the Operational Research Society. – 1969. – Vol. 20, No. 4. – P. 451-468.
17. Timmermann A. Forecast combinations // Handbook of Economic Forecasting. – 2006. – Vol. 1. – P. 135-196.
18. Петров В.А. Гибридные модели прогнозирования в экономике / В.А. Петров, С.И. Сидоров // Экономика и математические методы. – 2020. – Т. 56, № 2. – С. 45-58.
19. Сидоров И.В. Анализ временных рядов методами машинного обучения // Прикладная эконометрика. – 2019. – Т. 53, № 1. – С. 93-108.
20. Graves A. Generating sequences with recurrent neural networks // arXiv preprint arXiv:1308.0850. – 2013.
21. Федеральная служба государственной статистики. Регионы России. Социально-экономические показатели. – М.: Росстат, 2023. – 1242 с.
22. Минэкономразвития России. Стратегия пространственного развития Российской Федерации на период до 2025 года. – М., 2019.
23. Фаттахов Р.В. Экспертные оценки в региональном прогнозировании / Р.В. Фаттахов, М.М. Низамутдинов // Экономика региона. – 2018. – Т. 14, № 4. – С. 1278-1290.
24. Кендалл М. Ранговые корреляции. – М.: Статистика, 2017. – 216 с.
25. Armstrong J.S. Principles of Forecasting: A Handbook for Researchers and Practitioners. – Boston: Kluwer Academic Publishers, 2001. – 849 p.
26. Hyndman R.J. Another look at measures of forecast accuracy / R.J. Hyndman, A.B. Koehler // International Journal of Forecasting. – 2006. – Vol. 22, No. 4. – P. 679-688.
27. Tashman L.J. Out-of-sample tests of forecasting accuracy: an analysis and review // International Journal of Forecasting. – 2000. – Vol. 16, No. 4. – P. 437-450.
28. Филатов В.И. Структурные изменения в экономике России / В.И. Филатов, А.Н. Архипов // Вопросы экономики. – 2021. – № 3. – С. 67-84.
29. Глазьев С.Ю. Теория долгосрочного технико-экономического развития. – М.: ВладДар, 2022. – 512 с.
30. Stock J.H. Combination forecasts of output growth in a seven-country data set / J.H. Stock, M.W. Watson // Journal of Forecasting. – 2004. – Vol. 23, No. 6. – P. 405-430.

DOI: 10.24892/RIJE/20260103

# Hybrid Modeling for Long-Term Forecasts

Tsaplin S.T.

Bauman Moscow State University  
Moscow, Russian Federation

[serjio.tsa@yandex.ru](mailto:serjio.tsa@yandex.ru)

**Abstract.** This paper proposes a hybrid approach to long-term forecasting that combines expert foresight methods (Delphi method, technology roadmaps) with quantitative time series analysis algorithms (LSTM, ARIMA). The research aims to overcome the limitations of each method individually: expert assessment compensates for "blind spots" in data, while quantitative models reduce the subjectivity of expert scenarios. The proposed hybrid model architecture includes three levels: data collection and preprocessing level, expert analysis level, and quantitative modeling

level. Experimental studies showed an increase in long-term forecast accuracy by 15-20% compared to traditional approaches. The results confirm the effectiveness of integrating qualitative and quantitative methods for strategic planning and uncertainty management in the long term.

**Keywords:** hybrid modeling, long-term forecasting, Delphi method, technology roadmaps, LSTM, ARIMA, foresight