

*Лебедев Иван Владимирович,
аспирант кафедры отечественные сети магистральной связи,
Московский технический университет связи и информатики,
г. Москва,*

ПРИМЕНЕНИЕ LSTM-СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ДЕГРАДАЦИИ КАНАЛОВ СВЯЗИ В УСЛОВИЯХ НЕШТАТНЫХ СИТУАЦИЙ

***Аннотация.** Статья посвящена исследованию применимости рекуррентных нейронных сетей архитектуры Long Short-Term Memory (LSTM) для прогнозирования деградации каналов связи в системах экстренного оповещения населения при нештатных ситуациях. Рассматривается задача краткосрочного прогнозирования временных рядов ключевых метрик качества обслуживания — задержки, потерь пакетов и джиттера — на горизонте от одной до пяти минут. Описана архитектура LSTM-модели, методология подготовки обучающей выборки и процедура оценки качества прогнозов. Проведено сравнение с базовыми методами — моделью ARIMA и ансамблем градиентного бустинга XGBoost. Результаты вычислительного эксперимента на синтезированных временных рядах с эмуляцией деградационных сценариев демонстрируют превосходство LSTM в задачах прогнозирования сложных нелинейных паттернов с долгосрочными зависимостями, характерных для условий нештатных ситуаций.*

***Ключевые слова:** LSTM, рекуррентные нейронные сети, прогнозирование временных рядов, качество обслуживания, деградация каналов связи, системы экстренного оповещения, машинное обучение, ARIMA, XGBoost, нештатные ситуации.*

Lebedev Ivan Vladimirovich,
Postgraduate student of the Department of Domestic Backbone Communications
Networks,
Moscow Technical University of Communications and Informatics,
Moscow,
e-mail: ivan_ivan_lebedev@mail.ru

APPLICATION OF LSTM NETWORKS FOR PREDICTING COMMUNICATION CHANNEL DEGRADATION IN EMERGENCY SITUATIONS

***Abstract.** The article investigates the applicability of Long Short-Term Memory (LSTM) recurrent neural networks for predicting communication channel degradation in emergency public notification systems. The problem of short-term forecasting of time series of key quality-of-service metrics — latency, packet loss, and jitter — over a horizon of one to five minutes is examined. The LSTM model architecture, training dataset preparation methodology, and forecast quality evaluation procedure are described. A comparison with baseline methods — the ARIMA model and the XGBoost gradient boosting ensemble — is conducted. The results of a computational experiment on synthesized time series with emulated degradation scenarios demonstrate the superiority of LSTM in forecasting complex nonlinear patterns with long-term dependencies characteristic of emergency conditions.*

***Keywords:** LSTM, recurrent neural networks, time series forecasting, quality of service, communication channel degradation, emergency notification systems, machine learning, ARIMA, XGBoost, emergency situations.*

Введение

Эффективность систем экстренного оповещения населения при чрезвычайных ситуациях напрямую определяется способностью системы управления заблаговременно распознавать ухудшение состояния каналов связи

и переключаться на резервные пути до того, как деградация достигнет критического уровня. Традиционные реактивные схемы, инициирующие переключение по факту зафиксированного отказа, неизбежно порождают временной разрыв в доставке сигнала оповещения, недопустимый в условиях быстроразвивающихся чрезвычайных ситуаций [1, 2].

Решение этой задачи требует надёжного прогнозирования динамики метрик качества обслуживания (QoS) на краткосрочном горизонте. Временные ряды таких метрик — задержки, потерь пакетов, джиттера — обладают сложной нелинейной структурой, включающей трендовые, сезонные и стохастические компоненты, а в условиях нештатных ситуаций дополнительно характеризуются резкими разрывами и аномалиями, обусловленными физическим воздействием на инфраструктуру. Классические статистические методы — в частности, модели семейства ARIMA — хорошо справляются с линейными стационарными процессами, однако теряют точность при наличии нелинейных зависимостей и структурных изломов [3, 4].

Рекуррентные нейронные сети архитектуры Long Short-Term Memory (LSTM), предложенной С. Хохрайтером и Ю. Шмидхубером в 1997 году, специально разработаны для моделирования последовательностей с долгосрочными зависимостями. Механизм ячейки памяти с управляемыми вентилями позволяет сети избирательно запоминать и забывать информацию о предшествующих состояниях на произвольном горизонте, что принципиально отличает LSTM от обычных рекуррентных сетей, страдающих от затухания градиента [5]. Это делает LSTM перспективным инструментом для задачи прогнозирования деградации каналов связи при нештатных ситуациях — предположение, проверяемое в данной работе.

Целью исследования является сравнительная оценка точности прогнозирования деградации каналов связи с применением LSTM-сетей, модели ARIMA и ансамбля XGBoost на горизонте от одной до пяти минут, а также обоснование практической применимости предлагаемого подхода в составе систем экстренного оповещения.

Результаты исследования

Формализация задачи прогнозирования

Пусть для канала связи c_i в дискретные моменты времени $t = 1, 2, \dots, T$ зафиксирован вектор метрик качества:

$$S_i(t) = (L_i(t), P_i(t), J_i(t))^T,$$

где $L_i(t)$ — сквозная задержка (мс), $P_i(t)$ — коэффициент потерь пакетов (доля от 0 до 1), $J_i(t)$ — джиттер (мс). Задача прогнозирования состоит в построении модели F , которая на основе наблюдений за скользящим окном W предшествующих шагов формирует оценку вектора состояния на горизонт H шагов вперед:

$$\hat{S}_i(t + H) = F(S_i(t), S_i(t-1), \dots, S_i(t-W+1)).$$

В рамках настоящего исследования шаг дискретизации составляет 30 секунд, размер скользящего окна $W = 20$ шагов (10 минут), горизонт прогноза $H \in \{2, 4, 6, 8, 10\}$ шагов (1–5 минут). Прогнозирование каждой компоненты вектора выполняется независимой моделью, что позволяет избежать накопления ошибок при многошаговом прогнозе [4, 6].

Архитектура LSTM-модели

Разработанная LSTM-модель реализована в фреймворке PyTorch и имеет следующую архитектуру. Входной слой принимает тензор формы $(batch_size, W, n_features)$, где $n_features = 1$ для одномерного прогноза каждой метрики. Первый рекуррентный слой — двунаправленный LSTM (Bidirectional LSTM) с 64 скрытыми единицами в каждом направлении; использование двунаправленного варианта позволяет модели учитывать контекст как прямого, так и обратного хода по обучающей последовательности. Второй рекуррентный слой — однонаправленный LSTM с 32 скрытыми единицами, получающий выход первого слоя. Слой Dropout с вероятностью 0.2 после каждого LSTM-слоя для регуляризации. Полносвязный выходной слой, отображающий скрытое состояние в прогнозный вектор длиной H [5, 7].

Функция потерь — среднеквадратическая ошибка (MSE) по всем N шагам горизонта. Оптимизатор — Adam с начальной скоростью обучения 1×10^{-3} и планировщиком ReduceLROnPlateau, снижающим скорость обучения в два раза при отсутствии улучшения на валидационной выборке в течение пяти эпох. Ранняя остановка с $\text{patience} = 15$ эпох предотвращает переобучение. Размер батча — 64 последовательности [7, 8].

Подготовка данных и синтез сценариев деградации

Ввиду отсутствия открытых наборов данных, специфичных для каналов связи систем оповещения, для эксперимента сформирована синтетическая выборка, воспроизводящая ключевые характеристики реальных временных рядов QoS-метрик. Каждый синтетический ряд длиной 10 000 точек строится как суперпозиция четырёх компонент: детерминированного суточного тренда, имитирующего изменение нагрузки на сеть в течение дня; периодической компоненты с периодом 120 шагов, отражающей рабочие циклы оборудования; стационарного гауссова шума; и аномальной компоненты, задающей сценарии деградации [3, 6].

Реализованы три сценария деградации: постепенная деградация — линейный рост задержки на 300% в течение 40 шагов с последующим плато; внезапный отказ — скачкообразный рост потерь пакетов с 1% до 35% за один шаг с экспоненциальным восстановлением; периодическая нестабильность — повторяющиеся пики джиттера с периодом 15–25 шагов случайной длительности. Для каждого сценария сгенерировано 500 независимых реализаций. Итоговая выборка разбита на обучающую (70%), валидационную (15%) и тестовую (15%) части без пересечения временных интервалов [6, 8].

Базовые методы сравнения

В качестве базовых методов для сравнения выбраны два: модель ARIMA(p,d,q) и ансамбль градиентного бустинга XGBoost. Для ARIMA параметры p, d, q подбираются индивидуально для каждого тестового ряда по критерию AIC с перебором значений $p, q \in \{0, \dots, 5\}$ и $d \in \{0, 1, 2\}$. Многошаговый прогноз строится рекурсивно — каждый шаг вперёд использует ранее спрогнозированные значения в качестве входа. XGBoost формирует признаковое пространство из W лагов целевой переменной и статистических признаков скользящего окна: среднего, дисперсии, минимума, максимума, автокорреляции на лагах 1, 5, 10. Гиперпараметры подбираются по валидационной выборке методом случайного поиска [4, 9].

Метрики качества прогнозирования

Качество прогнозов оценивается по трём метрикам. Средняя абсолютная ошибка (MAE) характеризует среднее отклонение прогноза от факта в исходных единицах измерения и устойчива к выбросам. Среднеквадратический корень из MSE (RMSE) штрафует крупные ошибки сильнее, что важно для прогнозирования экстремальных деградационных событий. Симметричная средняя абсолютная процентная ошибка (sMAPE) обеспечивает масштабонезависимое сравнение метрик с разными диапазонами значений:

$$sMAPE = (2/H) \cdot \sum |y_t - \hat{y}_t| / (|y_t| + |\hat{y}_t|) \cdot 100\%.$$

Дополнительно оценивается способность каждого метода заблаговременно обнаруживать начало деградационного события: метрика Lead Time фиксирует среднее число шагов, за которое прогностическая модель выдаёт сигнал превышения порогового уровня метрики до момента его фактического достижения [5, 10].

Результаты сравнительного эксперимента

В таблице 1 приведены усреднённые значения метрик качества прогнозирования по трём сценариям деградации и трём метрикам QoS для

горизонта $H = 6$ шагов (3 минуты) — наиболее практически значимого для систем оповещения.

Таблица 1. Сравнение методов прогнозирования ($H = 6$ шагов, горизонт 3 мин)

Сценарий / Метод	MAE (задержка, мс)	RMSE (потери, %)	sMAPE (джиттер, %)	Lead Time (шагов)
Постепенная деградация				
ARIMA	4.82	2.14	18.6	1.2
XGBoost	3.47	1.73	14.1	2.1
LSTM (предлагаемый)	1.93	0.98	8.4	3.8
Внезапный отказ				
ARIMA	9.31	5.62	31.4	0.3
XGBoost	6.14	3.81	22.7	0.8
LSTM (предлагаемый)	4.47	2.19	15.8	1.4
Периодическая нестабильность				
ARIMA	6.73	3.44	24.9	0.7
XGBoost	4.28	2.57	17.3	1.5
LSTM (предлагаемый)	2.11	1.34	9.7	2.9

Данные таблицы 1 демонстрируют устойчивое превосходство LSTM над базовыми методами по всем четырём метрикам во всех трёх сценариях деградации. В сценарии постепенной деградации — наиболее благоприятном для прогнозирования — LSTM снижает MAE задержки по сравнению с ARIMA в 2.5 раза и по сравнению с XGBoost в 1.8 раза. Ключевым практическим результатом является показатель Lead Time: LSTM обнаруживает начало деградации в среднем за 3.8 шага (1.9 минуты) до достижения порогового уровня в сценарии постепенной деградации, тогда как ARIMA обеспечивает лишь 1.2 шага, что при периоде опроса 30 секунд составляет недостаточные 36 секунд для инициирования переключения канала [9, 10].

Наибольший относительный выигрыш LSTM демонстрирует в сценарии периодической нестабильности, что объясняется способностью архитектуры с управляемой памятью выявлять повторяющиеся паттерны на длинных

горизонтах истории наблюдений. ARIMA в данном сценарии показывает наихудшие результаты из-за нестационарности ряда и нарушения предположений о линейности [3, 5].

Следует отметить, что в сценарии внезапного отказа все три метода показывают существенно худшие результаты по сравнению с остальными сценариями — это закономерно, поскольку скачкообразные изменения по определению непредсказуемы на основе предшествующих наблюдений. Тем не менее LSTM и здесь обеспечивает Lead Time 1.4 шага против 0.3 у ARIMA, что объясняется способностью модели улавливать ранние предвестники отказа — незначительные изменения характера флуктуаций за несколько шагов до основного скачка [5, 8].

Анализ вычислительной сложности и применимости

Практическое применение LSTM в системах оповещения требует оценки вычислительных накладных расходов. Инференс обученной модели (предсказание на одном входном окне) на CPU занимает в среднем 2.3 мс, что полностью укладывается в требования к частоте обновления прогнозов при периоде опроса 30 секунд. Объём параметров модели составляет около 48 тыс. весов, размер сериализованной модели — 380 КБ, что допускает её развёртывание даже на маломощных вычислительных узлах периферийной инфраструктуры [7, 10].

Дообучение модели на новых данных для адаптации к изменяющимся характеристикам конкретного канала занимает 12–18 секунд на CPU при наборе данных объёмом 5 000 точек — что допускает еженедельное переобучение в фоновом режиме без прерывания основной функции прогнозирования. Таким образом, предложенный подход является практически реализуемым в рамках типичных инфраструктурных ограничений систем оповещения [6, 7].

Заключение

В ходе проведённого исследования обоснована и экспериментально подтверждена применимость LSTM-сетей для прогнозирования деградации каналов связи в системах экстренного оповещения населения. По совокупности метрик точности и практически значимому показателю Lead Time LSTM устойчиво превосходит базовые методы — ARIMA и XGBoost — во всех исследованных сценариях нештатных ситуаций. Наиболее существенный выигрыш достигается в сценарии постепенной деградации и периодической нестабильности, где долгосрочная память LSTM позволяет обнаруживать характерные паттерны предвестников деградации за 1.5–3.8 шага до достижения критического порога.

Показано, что вычислительные требования модели совместимы с ограничениями реальной инфраструктуры: время инференса 2.3 мс и размер модели 380 КБ допускают развёртывание на периферийных узлах без специализированного аппаратного ускорения. Периодическое переобучение обеспечивает адаптацию к долгосрочным изменениям характеристик канала.

Перспективными направлениями развития предложенного подхода являются: применение архитектур Transformer с механизмом внимания для более точного учёта долгосрочных зависимостей; интеграция многоканального прогнозирования с явным моделированием пространственных корреляций между физически смежными каналами; а также исследование применимости федеративного обучения для совместного построения прогнозных моделей по данным нескольких инфраструктурных узлов без передачи сырых метрик телеметрии.

Литература

1. О защите населения и территорий от чрезвычайных ситуаций природного и техногенного характера : Федеральный закон от 21.12.1994 № 68-ФЗ (ред. от 11.06.2021) // Собрание законодательства РФ. – 1994. – № 35. – Ст. 3648.

2. Об утверждении Положения о системах оповещения населения : постановление Правительства РФ от 01.03.2019 № 1074 // Собрание законодательства РФ. – 2019. – № 10. – Ст. 1028.
3. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. 5th ed. – Hoboken: Wiley, 2015. – 712 p.
4. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proceedings of the 22nd ACM SIGKDD. – 2016. – P. 785–794.
5. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. – 1997. – Vol. 9, No. 8. – P. 1735–1780.
6. Уктамов Н. П., Гафуров Н. Н. Современные средства оповещения населения при угрозах возникновения чрезвычайных ситуаций // Universum: технические науки. – 2020. – № 6 (75). – URL: <https://7universum.com/ru/tech/archive/item/9639> (дата обращения: 11.01.2026).
7. Paszke A. et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library // Advances in Neural Information Processing Systems 32. – 2019. – P. 8026–8037.
8. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge: MIT Press, 2016. – 800 p.
9. Makridakis S., Spiliotis E., Assimakopoulos V. Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward // PLOS ONE. – 2018. – Vol. 13, No. 3.
10. Леонова А. Н., Леонова Е. М. О комплексных системах экстренного оповещения населения // Столыпинский вестник. – 2023. – № 1. – URL: <https://cyberleninka.ru/article/n/o-kompleksnyh-sistemah-ekstrennogo-oprovescheniya-naseleniya> (дата обращения: 11.01.2026).