СРАВНИТЕЛЬНЫЙ АНАЛИЗ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ КАНАЛОВ СВЯЗИ В ЗАДАЧЕ ГАРАНТИРОВАННОЙ ДОСТАВКИ ДОКУМЕНТОВ

Рашидов Ж.Ж.
Институт развития цифровых технологий и искусственного интеллекта Республики Узбекистан

Аннотация. *В статье проведено сравнительное исследование моделей машинного обучения для прогнозирования отказов каналов связи в системах гарантированной доставки документов. Сравнены логистическая регрессия и градиентный бустинг LightGBM по основным метрикам качества. Установлено, что логистическая регрессия показала более высокие значения ROC-AUC, PR-AUC и recall, что позволяет использовать её в качестве базовой модели прогнозирования отказов.*

Ключевые слова: *прогнозирование отказов, машинное обучение, логистическая регрессия, градиентный бустинг, отказоустойчивая маршрутизация, системы электронного документооборота.*

Актуальность. Существующие механизмы отказоустойчивой маршрутизации (MPLS Fast Reroute, OSPF-TE, механизмы восстановления в SDN) носят реактивный характер: они реагируют на сбой сети уже после его возникновения. Для задачи гарантированной доставки документов в системах электронного документооборота проактивное прогнозирование вероятности отказа канала связи, интегрированное с приоритетом получателя, позволяет заблаговременно перенаправлять маршрут до фактического сбоя, однако выбор конкретной модели машинного обучения для такого прогнозирования требует эмпирического обоснования, а не априорного назначения.

Постановка задачи. Функция вероятности отказа $p: E \to [0, 1]$ формализована как задача бинарной классификации: для каждого канала e строится вектор признаков телеметрии $x(e) = (f_1, \ldots, f_5)$ — загрузка канала, число ретрансмиссий, задержка, история отказов узла, возраст оборудования, — а модель $p\theta(e) = P(\text{отказ} = 1 \mid x(e))$ обучается на размеченных наблюдениях $(x(e),$

y(e)). Сравниваются две модели: логистическая регрессия (интерпретируемая, линейная разделяющая поверхность) и градиентный бустинг над деревьями решений (LightGBM, способный выявлять нелинейные зависимости).

Методология эксперимента. Использован набор данных, сгенерированный на 300 случайных связных топологиях по 25 узлов (22 679 наблюдений-рёбер, доля положительного класса 12,9%). Метка отказа моделировалась как результат испытания Бернулли с вероятностью, заданной логистической функцией от признаков и случайного шума. Разбиение на обучающую и тестовую выборки выполнено в пропорции 80/20 по топологиям (group split), что исключает утечку данных между рёбрами одной топологии. Логистическая регрессия обучена с балансировкой классов на стандартизованных признаках; LightGBM — с компенсацией дисбаланса классов и ранней остановкой по валидационному ROC-AUC.

Результаты. Итоговые метрики качества на тестовой выборке приведены в таблице.

Метрика	Logistic Regression	LightGBM
ROC-AUC	0,747	0,733
PR-AUC	0,346	0,327
F1-score	0,353	0,357
Precision	0,241	0,274
Recall	0,661	0,511

По важности признаков (LightGBM) наибольший вклад вносят задержка (43,0%) и загрузка канала (21,5%), далее — возраст оборудования (20,0%) и история отказов узла (11,9%); наименее информативно число ретрансмиссий (3,7%). Логистическая регрессия показала незначительно более высокие ROC-AUC и PR-AUC и заметно более высокий recall при сопоставимом F1-score, что объясняется способом генерации меток (логистическая зависимость от линейной комбинации признаков) и говорит о том, что более сложная модель не даёт автоматического прироста качества.

Заключение. В качестве базовой модели ИИ-модуля прогнозирования отказов принята логистическая регрессия — как показавшая не худшее, а по ряду метрик лучшее качество при существенно более высокой интерпретируемости

коэффициентов, что важно для последующего анализа модулем принятия решений о приоритетном восстановлении маршрута. Результаты получены на синтетических данных, сгенерированных для методологической проверки эксперимента; дообучение и повторная оценка моделей на данных реальной сетевой телеметрии запланированы на следующем этапе исследования в рамках экспериментальной апробации предложенного механизма гарантированной доставки документов.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Menaceur A., Drid S., Rahouti M. Fault Tolerance and Failure Recovery Techniques in Software-Defined Networking: A Comprehensive Approach // Journal of Network and Systems Management. — 2023.

2. A Survey of Link Failure Detection and Recovery in Software-Defined Networks // Computers, Materials & Continua. — 2025. — Vol. 82, No. 1.

3. Yao L., Bi J., Guo L. On the Cascading Failures of Multi-Controllers in Software Defined Networks // Proceedings of IEEE International Conference on Network Protocols. — 2013.

4. Hagberg A., Swart P., Chult D.S. Exploring Network Structure, Dynamics, and Function using NetworkX // Proceedings of the 7th Python in Science Conference (SciPy 2008). — P. 11–15.