

БЫСТРАЯ ОЦЕНКА ВЕРОЯТНОСТИ УСПЕШНОЙ ДОСТАВКИ ЗАЯВКИ В ТАНДЕМНОЙ СЕТИ МАССОВОГО ОБСЛУЖИВАНИЯ

А.А. Мухтаров

Институт проблем управления им. В.А. Трапезникова РАН

Россия, 117997, Москва, Профсоюзная ул., 65

E-mail: amukhtarov@ipu.ru

Ключевые слова: многофазные сети, вероятность доставки, аппроксимация данных имитационной модели.

Аннотация: При проектировании новых или усовершенствовании существующих телекоммуникационных сетей связи проводят оценку характеристик производительности сети – межконцевая задержка, потери в каналах и т.д. Для их расчета прибегают к использованию аппарата теории массового обслуживания и имитационного моделирования. В ряде случаев такой подход имеет существенный недостаток – невозможность получения быстрой оценки для сложных моделей. Особенно это заметно при многократном использовании имитационного моделирования для получения оценок, например, при синтезе топологической структуры сети. В работе предлагается использование моделей аппроксимации для оценки вероятности успешной доставки в тандемной сети массового обслуживания.

1. Введение

Многофазные сети массового обслуживания позволяют рассчитывать оценки характеристик производительности различных сложных телекоммуникационных сетей [1–4]. Если для простейших случаев, когда используются экспоненциальные распределения времени обслуживания и пуассоновские входящие потоки, можно получить аналитический расчет, то уже для сложных сетей большой размерности, в большинстве случаев, получить аналитическое решение практически невозможно. В этом случае прибегают к имитационному моделированию. Главная трудность имитационного моделирования – высокая вычислительная сложность. Для решения этой проблемы используют аппроксимацию с помощью методов машинного обучения [5–9]. В работе предлагается использовать модели классификации для получения быстрых оценок характеристик производительности сети, в нашем случае оценки вероятности успешной доставки заявок. Для обучения таких моделей использовать синтетические данные, сгенерированные с помощью метода Монте-Карло.

2. Тандемная сеть массового обслуживания

Рассмотрим тандемную (многофазную) сеть массового обслуживания (рис. 1) длиной N , емкостью очередей M и с фазовым распределением времени обслуживания $Y_k \sim PH(S_k, \bar{\tau}_k)$, $k = 1, 2, \dots, N$. Для упрощения выкладок будем считать, что время обслуживания на всех приборах распределено одинаково, то есть $S_1 = S_2 = \dots = S_N$ и $\bar{\tau}_1 = \bar{\tau}_2 = \dots = \bar{\tau}_N$. В реальной жизни чаще всего удобнее пользоваться сетевым дампом, поэтому функции распределения времени обслуживания и входящего потока заявок в данной работе будем восстанавливать по первым трем моментам с помощью методов, описанных в работах [10, 11].

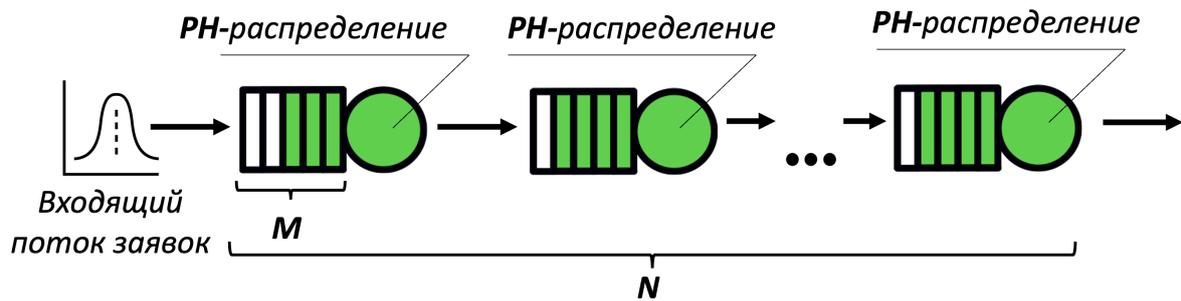


Рис. 1. Тандемная сеть массового обслуживания

3. Модели оценок вероятности успешной доставки заявок в тандемной сети массового обслуживания

Для генерации синтетических данных необходимых для обучения моделей классификации воспользуемся имитационной моделью (метод Монто-Карло). Для этой цели использовался Open-Source проект для расчета стохастических моделей <https://github.com/iru69/pyqumo>. На ее вход поступают данные, сгенерированные случайным образом (табл. 1). На выходе рассчитываются вероятности потерь P_N заявок. Объем выборки составил 100'000 строк.

В случае оценки такой характеристики как вероятность доставки заявок не критично знать действительные значения величин. Гораздо важнее получить прогноз – является ли доставка «успешной». Зададим граничное условие B для условия успешной доставки. Будем классифицировать вероятности доставки на две группы:

- успешная доставка, $1 - P_N \in [B, 1]$;
- потеря заявок, $P_N \in [0, B)$.

Для всех моделей в численном эксперименте граница задана равной $B = 0.9$.

Для подготовки моделей классификации использовались следующие методы: логистическая регрессия, дерево решений, градиентный бустинг и искусственная

Таблица 1. Входные параметры имитационной модели

Параметр	Диапазон
Время между поступлениями заявок	
Среднее значение, m_a	$\sim (0, 10)$
Коэффициент вариации, c_a	$\sim (0.5, 3)$
Коэффициент асимметрии, γ_a	$\sim (c_a - \frac{1}{c_a}, 100)$
Время обслуживания заявок на фазах	
Среднее значение, m_s	$\sim (0, 10)$
Коэффициент вариации, c_s	$\sim (0.5, 3)$
Коэффициент асимметрии, γ_s	$\sim (c_s - \frac{1}{c_s}, 100)$
Размер буфера очередей на фазах, M	$\{6, 7, \dots, 10\}$
Количество фаз в сети, N	$N = \{1, 2, \dots, 20\}$

нейронная сеть. На рис. 2 представлены результаты оценок вероятности успешной доставки на тестовой выборке. Оранжевым цветом указаны оценки вероятности потерь заявок, зеленым цветом вероятности успешной доставки. В таблице 2 представлены полученные метрики.

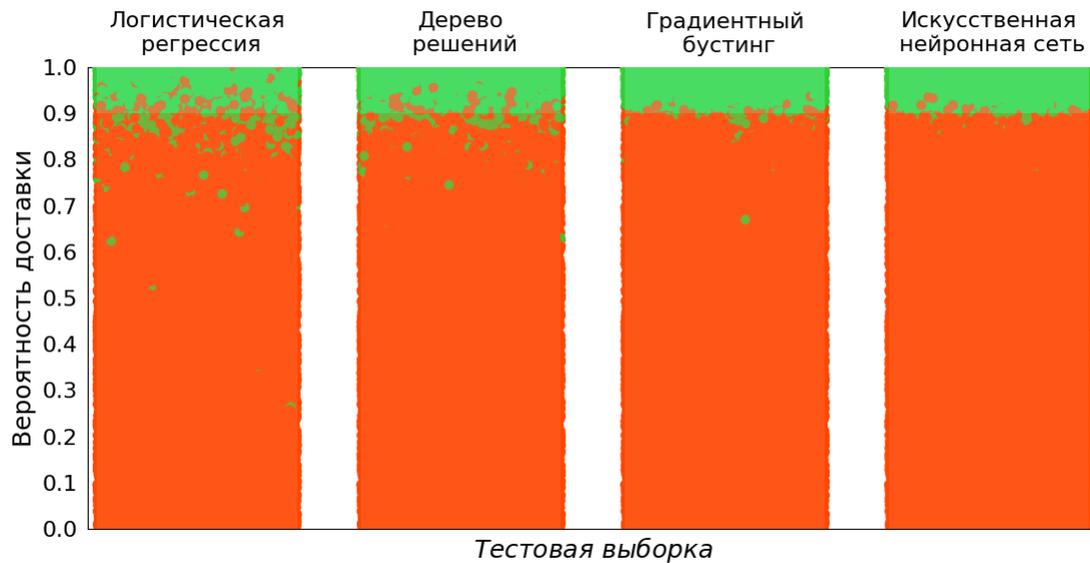


Рис. 2. Прогнозы вероятности успешной доставки заявок на тестовой выборке

На примере тандема с длиной $N = 10$ представлены оценки успешной доставки всех моделей (рис. 3). Трендом указаны действительные значения вероятности доставки $1 - P_N$ для различных коэффициентов загрузки ρ . Зеленым цветом представлены прогнозы успешной доставки ($1 - \widehat{P}_N \geq B$) и красным цветом вероятности потерь ($1 - \widehat{P}_N < B$). Здесь можно выделить градиентный бустинг и искусственную нейронную сеть, предоставляющие наилучшие прогнозы вероятности успешной доставки.

Для полученных моделей в таблице 3 представлено времена счета полученных

Длина тандема = 10

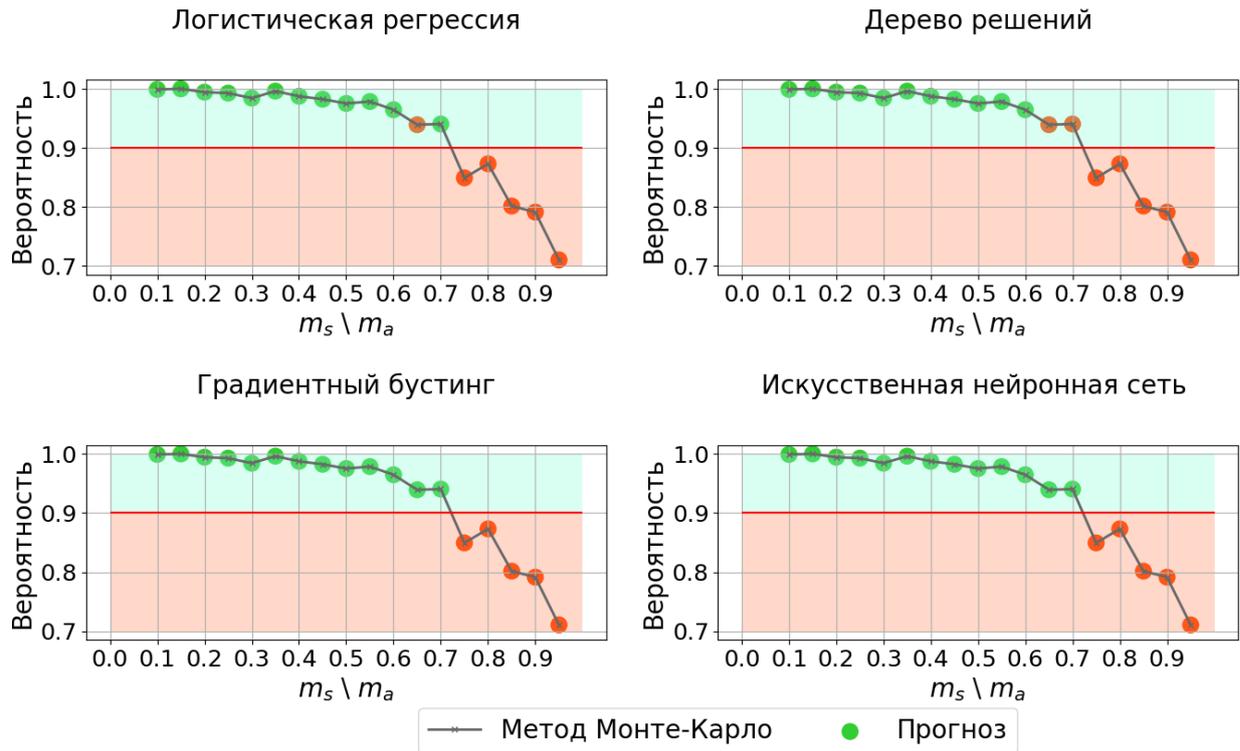


Рис. 3. Тандемная сеть массового обслуживания

Таблица 2. Метрики

Модель	<i>Precision</i>	<i>Recall</i>	F_1
Логистическая регрессия	0.804	0.821	0.813
Дерево решений	0.9618	0.905	0.912
Градиентный бустинг	0.966	0.969	0.968
Искусственная нейронная сеть	0.977	0.951	0.964

Таблица 3. Оценка времени счета моделей

Модель	Время счета, с
Метод Монте-Карло	172.2
Логистическая регрессия	$5.25 \cdot 10^{-6}$
Дерево решений	$5.01 \cdot 10^{-6}$
Градиентный бустинг	$4.77 \cdot 10^{-6}$
Искусственная нейронная сеть	$5.25 \cdot 10^{-6}$

моделей оценок вероятности успешной доставки. Объем выборки, на которой измерялось время, составляет 360. Целесообразно сравнивать время счета для целой выборки, так как для единичных случаев время счета будет варьироваться, как минимум, в зависимости от длины тандема. Очевидно, что в каждую новую прогонку моделей, время будет также варьироваться в зависимости от занятости

CPU рабочей машины. Тем не менее можно оценить, что время счета моделей на несколько порядков ниже чем время счета метода Монте-Карло.

4. Заключение

В статье представлено исследование эффективности применения различных методов машинного обучения для получения оценок вероятности успешной доставки заявок в тандемной сети массового обслуживания. Численные результаты показывают адекватность такого подхода в практических случаях.

Исследование выполнено за счет гранта Российского научного фонда №22-49-02023, <https://rscf.ru/project/22-49-02023/>.

Список литературы

1. Dudin A.N., Klimenok V.I., Vishnevsky V.M. *The Theory of Queuing Systems with Correlated Flows*. Springer, 2019.
2. Md Abu Baker Siddiki Abir, Mostafa Zaman Chowdhury, Yeong Min Jang. A Software-Defined UAV Network Using Queueing Model. *IEEE Access*. 2023. Vol. 11. P. 91423–91440.
3. Ram Chakka, Tien Van Do, and Zsolt Pandi. A Generalized Markovian Queue and Its Applications to Performance Analysis in Telecommunications Networks. *Performance Modelling and Analysis of Heterogeneous Networks*. 2022. P. 371–387.
4. Larionov A.A., Mukhtarov A.A., Sokolov A.M. The calibration method of a tandem queueing model with PH service time using NS-3 simulation of a multihop wireless network. *Journal of Physics: Conference Series*. 2021. Vol. 2091, No. 1. P. 012030.
5. Vishnevsky V., Klimenok V., Sokolov A., Larionov A. Performance Evaluation of the Priority Multi-Server System MMAP/PH/M/N Using Machine Learning Methods. *Mathematics*. 2021. Vol. 9, No. 24. P. 3236.
6. Efrasinin D., Vishnevsky V., Stepanova N. Optimal Scheduling in General Multi-Queue System by Combining Simulation and Neural Network Techniques. *Sensors*. 2023. Vol. 23, No. 12.
7. Kudou T., Nii S., Okuda T. A Performance Evaluation of Tandem Queueing Systems by Machine Learning. *Proceedings of the 2022 IEEE International Conference on Consumer Electronics, Taiwan, ICCE-Taiwan, 2022*. 2022. P. 389–390.
8. Kudou T., Okuda T. A Time Series Analysis of Single Server Queueing Systems by Using Machine Learning. 2023. P. 327–328.
9. Vercellino C., Scionti A., Varavallo G., Viviani P., Vitali G., Terzo O. A Machine Learning Approach for an HPC Use Case: the Jobs Queueing Time Prediction. *Future Generation Computer Systems*. 2023. Vol. 143. P. 215–230.
10. Telek M., Heindl A. Matching Moments For Acyclic Discrete And Continuous Phase-Type Distributions Of Second Order. *International Journal of Simulation Systems, Science and Technology*. 2003. Vol. 3.
11. Johnson M.A., Taaffe M.R. Matching moments to phase distributions: Mixtures of erlang distributions of common order. *Communications in Statistics. Stochastic Models*. 1989. Vol. 5, No. 4. P. 711–743.