

Применение методов машинного обучения для управления перегрузкой в каналах наложенной сети

Оконишников Арий Ариевич¹, Степанов Евгений Павлович²

¹ Кафедра автоматизации систем вычислительных комплексов, e-mail: a3.okonishnikov@mail.ru

² Кафедра автоматизации систем вычислительных комплексов, e-mail: estepanov@lvk.cs.msu.ru

Одним из методов обеспечения качества сервиса являются алгоритмы управления перегрузкой (АУП) [1]. Они позволяют контролировать размер окна перегрузки, тем самым варьируя число пакетов, отправляемых в сеть.

В работе основное внимание уделено АУП, которые учитывают прогноз параметров качества сервиса: вероятности потери пакета - L , задержки доставки пакета - RTT , доступной пропускной способности канала - R . Прогноз составляется на время существования транспортного потока на основе работы методов [2], позволяющих оценивать параметры качества сервиса. Существующие АУП не имеют доступа к такому прогнозу и сами оценивают параметры качества сервиса во время работы. Их оценки не всегда корректны, что приводит к установке неоптимального окна перегрузки, и как следствие - заполнению буфера получателя или неполному использованию доступной пропускной способности. В работе рассматривается задача нахождения оптимального размера окна перегрузки на основе данных описанного прогноза.

В формальной постановке задачи входные параметры представлены тройкой RTT, L, R . Требуется найти окно перегрузки - $CWND$. В работе предложен алгоритм на основе BBR FORECAST [9]. Особенность алгоритма BBR FORECAST заключается в состоянии FORECAST, в котором АУП находится в начале работы и до тех пор, пока прогноз остается верным. Ошибка в прогнозе обнаруживается при отклонении круговой задержки и процента потери пакетов на заданный долю. В таком случае АУП переходит в состояние PROBE_RTT [3] и действует далее по алгоритму BBRv2 [3].

Основной идеей рассматриваемого в работе подхода является поиск окна перегрузки решением задачи регрессии методом машинного обучения (ML) с учителем [5] в состоянии FORECAST. Для выбора такого алгоритма проведен обзор, в результате которого выбраны случайный лес [6], градиентный бустинг [7], полиномиальная регрессия [8] по следующим критериям: длительность обучения модели, количество гиперпараметров, доля ошибки, интерпретируемость. Для выбранных методов проведен сравнительный анализ, по итогам которого самый точный регрессор встроен в АУП. Предлагается методика сравнения соблюдения прогноза предложенного алгоритма и алгоритма без прогноза на модели клиент-сервера реализации протокола QUIC ngtcp2 [4].

СПИСОК ЛИТЕРАТУРЫ

- [1] M. Allman, V. Paxson. Request for Comments: 5681 - TCP Congestion Control. Сентябрь 2009
- [2] Dixon Salcedo, Cesar D. Guerrero and Roberto Martinez. Available Bandwidth Estimation Tools: Metrics, Approach and Performance. Декабрь 2018
- [3] Neal Cardwell, Yuchung Cheng - BBR Congestion Control. Сентябрь 2022
- [4] ngtcp2 [HTML] <https://github.com/ngtcp2/ngtcp2/>
- [5] scikit-learn - Supervised Learning [HTML] https://scikit-learn.org/stable/supervised_learning.html
- [6] scikit-learn - Random Forest [HTML] <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>
- [7] scikit-learn - Gradient Boosting [HTML] <https://xgboost.readthedocs.io/en/stable/parameters.html>
- [8] scikit-learn - Polynomial Features [HTML] <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.PolynomialFeatures.html>
- [9] Степанов Е. П., Оконишников А. А. Разработка алгоритма управления перегрузкой на основе прогноза состояния канала для протокола пользовательских дейтаграмм // Ломоносовские чтения-2022: научная конференция, факультет ВМК МГУ имени М.В.Ломоносова. Тезисы докладов. — СЕКЦИЯ ВЫЧИСЛИТЕЛЬНОЙ МАТЕМАТИКИ И КИБЕРНЕТИКИ. — Москва: Москва, 2022. — С. 160–161.