



### Литература

1. Рекомендации по метрологии РМГ 29-2013. Метрология. Основные термины и определения.
2. Пригожин, И.Р. Порядок из хаоса / И. Пригожин, И. Стенгерс. - Москва : Едиториал УРСС, 2003. - 310 с.
3. «Наука логики» / Георг Вильгельм Фридрих Гегель: АСТ; Москва; 2018.
4. Ferrini, C. Hegel's revisions of the logic of being (2020) Rivista di Storia della Filosofia, (2), pp. 199-221, DOI: 10.3280/SF2020-002003.
5. Фихтенгольц Г.М. Курс дифференциального и интегрального исчисления. Т.1. – М: Наука, 1969. – 616 с.

О.Д. Бербасов, А.Ю. Привалов

## ПРОГНОЗИРОВАНИЕ МОМЕНТА ПЕРЕПОЛНЕНИЯ БУФЕРА В УЗЛЕ ТЕЛЕКОММУНИКАЦИЙ С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ

(Самарский университет)

Рассматривается возможность использования нейросети в задаче определения момента переполнения буфера в телекоммуникационном оборудовании (например, в магистральном коммутаторе), для того, чтобы заранее включать механизмы управления потоком с целью избежать входа телекоммуникационной сети в состояние перегрузки. Для этого рассматривается система массового обслуживания с одним прибором и бесконечной очередью, входным потоком для которой является реальный трафик (взятый из репозитория [1]). Это трассы нескольких минут интернет-трафика магистральной линии связи Нью-Йорк – Чикаго в 2016 году.

Реальный трафик такого вида обладает рядом специфических особенностей, сильно отличающий его от классических моделей теории телетрафика, и сильно затрудняющий создание модели, обладающей хорошей для практики точностью в предсказании поведения в реальном масштабе времени. К таким особенностям прежде всего относится большая пачечность и сильная коррелированность. Проблемы построения адекватной модели такого трафика в течении долгого времени привлекают большое внимание научного сообщества (см. например, [2,3]), но до сих пор не утратили актуальность. После начала бурного развития нейросетевых подходов в самых разных областях, и в области анализа и управления телекоммуникационным трафиком такие исследования и в области анализа и управления телекоммуникационным трафиком активно ведутся (см., например, [3-5]). Представляемая работа также посвящена этой теме.

Для проведения экспериментов трассы реального трафика, представляющие из себя данные о каждом проходящем пакете, такие, в частности, как время прихода и размер в байтах, преобразуются во временной ряд, члены которого равны суммарному количеству информации, прошедшему по линии связи за



очередной временной шаг (сумме размеров пакетов, пришедших в течение этого временного шага). Каждый временной шаг очередной член ряда добавляется к содержимому буфера, а перед началом следующего временного шага из буфера, если он не пуст, забирается количество информации, пропорциональное скорости выходящего канала связи. Эта скорость подбирается таким образом, чтобы коэффициент загрузки выходящей линии связи имел бы заданное значение. Интенсивность входного потока оценивается как среднее значение временного ряда, взятое по всей его реализации. Временной ряд, члены которого являются количеством информации, находящимся в буфере на очередном временном шаге, и является предметом изучения.

Для предсказания поведения этого временного ряда используется нейросеть типа многослойный персептрон, которая состоит из трёх слоёв. Первый слой является входным и содержит столько нейронов, сколько временных шагов вмещает окно прогноза. Второй слой содержит  $n$  нейронов с функцией активации softmax. Причем  $n$  подбирается оптимальным при анализе получаемых прогнозов. Выходом нейронной сети служит третий слой, состоящий из единственного нейрона, который выдает значения от 0 до 1. Это значение равно вероятности переполнения буфера в прогнозируемый момент времени.

Для обучения нейронной сети формируется множество обучающих наборов. Каждый такой набор состоит из содержимого окна прогнозирования и значения вероятности переполнения буфера в соответствующий момент времени. В обучающих наборах, в качестве значения вероятности переполнения используются точные значения, то есть значению 0 соответствует ситуация «буфер не переполнится», а 1 – «буфер переполнится». При обучении нейронной сети используется метод стохастического градиентного спуска Adam. В качестве функции потерь используется средняя квадратичная ошибка (MSE).

### Литература

1. CAIDA Data - Overview of Datasets, Monitors, and Reports. [Электронный ресурс]. – Режим доступа: <https://www.caida.org> (дата обращения 20.01.2022), свободный.
2. Paxson, V. Wide-Area Traffic: The Failure of Poisson Modeling [Text] / V. Paxson, S. Floyd // IEEE ACM Transactions on Networking, 3(3). – NJ, June 1995. – P. 226-244.
3. Leland, W.E. High time-resolution measurement and analysis of LAN traffic: Implications for LAN interconnection [Text] / W. Leland, D.V. Wilson // Proc. IEEE INFOCOM '91. – Bal Harbor, FL, April 1991. – P. 1360-1366.
4. Mondragón, R. J., Chaotic maps for traffic modelling and queueing performance analysis [Text] / R. J. Mondragón, D. K. Arrowsmith and J. M. Pitts // Performance Evaluation. – Netherlands, 2001. – P. 223-240.
5. Willinger, W. A bibliographical guide to self-similar traffic and performance modeling for modern high-speed networks [Text] / W. Willinger, M.S. Taqqu, A. Erramilli // Clarendon press. – Oxford, 1996. – P. 339-366.