

輻輳ウィンドウを用いたRNNによるネットワークのトラフィック変動予測

小山内 遥香[†]中尾 彰宏[‡]山本 周[‡]山口 実靖[§]小口 正人[†][†]お茶の水女子大学[‡]東京大学[§]工学院大学

1. はじめに

現在、スマートフォンや自動車、家電など身の回りのあらゆるものがインターネットに接続されており、通信は、電気やガス、水道と並ぶ生活を送るために必要不可欠なものとなっている。そのため、突然発生する通信障害により通信が利用できなくなると人々を混乱に陥れる可能性が大きい。

通信障害は、大規模災害による被災地内外からの通信過多による輻輳、DDoS 攻撃や同時に起こる OS アップデートなど、様々な原因で引き起こされる。

これらの通信障害は起こってからでは、対応が手遅れである場合が多く、確度の高い予測をし、事前に輻輳を抑制することが必要である。

また、近年深層学習の技術が発達してきている。深層学習は、画像や音声の認識、自動車の自動運転など様々な分野に応用され、非常に高い解析性能により社会に多大な利益をもたらしている。

そのため、網内における深層学習を用いたトラフィック変動の学習により、トラフィック集中を早期に検知し、効率的に対応するための技術に期待が集まっている。

本論文では、深層学習のモデルの一種である Recurrent Neural Network(RNN) を用いてトラフィック異常の情報を抽出し、トラフィック変動の兆候を掴むための手法の提案と作成した予測モデルの性能評価を行う。

2. 深層学習

深層学習は、機械学習の一種であるニューラルネットワークの階層を深めたアルゴリズムである。深層学習は、画像や音声の認識、自動車の自動運転など様々な分野に応用され、社会に大きな利益をもたらしており注目されている。

2.1 RNN

RNN は、時系列データの学習に適したネットワークで、以前に計算された情報を記憶することができる。しかし、

系列が長く深いネットワークになると、誤差逆伝播のアルゴリズムでは勾配の消失、発散などの問題が生じてしまう。

この問題を解決するために RNN を改良したモデルが Long Short-Term Memory(LSTM) である。LSTM は、RNN に入力ゲート、出力ゲート、忘却ゲートを導入することにより、RNN では扱えなかった長期依存を扱えるようになっている。

3. 実験

本研究では、LSTM を用いて 1 秒後のパケット数を予測する実験を行う。使用した深層学習のフレームワークは PFN 社の Chainer[1] である。

3.1 実験概要

TCP では、輻輳制御が行われている。TCP の輻輳制御では、cwnd (輻輳ウィンドウ) などのパラメータが用いられているため、入力データに cwnd を加えれば予測精度が向上すると考えられる。

本章では、学習データとして iPerf での TCP 通信時にパケットを取得するとともに、クライアントそれぞれの cwnd を取得した。取得したデータを用いて、cwnd を加えた場合と加えなかった場合でそれぞれ学習と性能評価を行なった。実験環境は図 1 のようになっている。

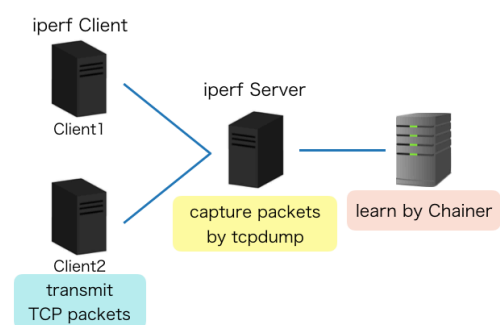


図 1: 実験環境

入力データには $t-9$ 秒～ t 秒の 10 秒間に送受信したパケットから 1 秒おきに以下の 5 種の特徴量を導出したものとしており、詳細は以下である。

- パケット送受信時刻 t
- パケットサイズの平均
- 時刻 t に送受信したパケット数
- クライアント 1 の cwnd 値 (cwnd ありの場合)

Prediction of Variation in Network Traffic by RNN Using Congestion Window

Haruka Osanai[†]

Akihiro Nakao[‡]

Shu Yamamoto[‡]

Saneyasu Yamaguchi[§]

Masato Oguchi[†]

[†]Ochanomizu University

[‡]University of Tokyo

[§]Kogakuin University

● クライアント2の cwnd 値 (cwnd ありの場合)

正解データは時刻 $t+1$ 秒に届いたパケット数を 0~1 に正規化した値である。また、学習時の epoch 数は 1000、隠れ層の数は 49 としている。

3.2 学習




図 2: 学習データと予測結果 (cwnd なし)

図 3: 学習データと予測結果 (cwnd あり)




図 4: 学習データ取得時の cwnd の変化

学習モデルに再度学習データを入力した場合には、cwnd なしの場合 (図 2) と cwnd ありの場合 (図 3) はどちらも学習データの特徴をうまく学習できていることがわかる。

図 4 は学習データ取得時の cwnd の変化のグラフである。通信の変化のタイミングで cwnd も大きく変化していることがわかる。

3.3 性能評価

作成した学習モデルにバリデーションデータを入力し性能評価を行った。cwnd なしの場合 (図 5) と cwnd ありの場合 (図 6) を比較すると、cwnd ありの場合の方が早い段階でパケット数が増えることが予測できている。輻輳予測に関しては、早期に輻輳を予測し対処することが重要になる。そのため、cwnd ありの場合は、精度の観点では改善の余地があるが、より早い段階でパケット数の増加を予測できている、予測により影響を与えるのではないかと考えられる。

図 7 は学習データ取得時の cwnd の変化のグラフである。通信の変化のタイミングで cwnd も大きく変化していることがわかる。

4. まとめと今後の予定

深層学習のモデルで、RNN の一種である LSTM をネットワークトラフィックの予測に応用し、性能評価を行なった。




図 5: バリデーションデータと予測結果 (cwnd なし)

図 6: バリデーションデータと予測結果 (cwnd あり)




図 7: データ取得時の cwnd の変化

今回は、cwnd を用いない場合と cwnd を用いた場合の 2 種類の実験を行ったところ、入力データに cwnd を用いて学習を行なった場合、予測精度の点では改善の余地があるものの、cwnd を用いない場合と比べて早期にパケット増加の予測ができた。そのため、学習の特徴量に cwnd を追加することは学習により影響を与えるのではないかと考えられる。

今回の実験では、iPerf 通信にサーバ 1 台、クライアント 2 台の計 3 台のマシンを用いており、比較的シンプルなトラフィックでの学習、予測を行なった。今後は学習データの増加、マシンの台数を増やしての通信、実際に輻輳が起きているデータを用いるなど、より複雑なトラフィックでの実験を行いたいと考えている。

謝辞

本研究は一部、JST CREST JPMJCR1503 および総務省戦略的情報通信開発推進事業 (SCOPE) 先進的通信アプリケーション開発推進型研究開発によるものである。

参考文献

[1] Tokui, S., Oono, K., Hido, S. and Clayton, J.: Chainer: a Next-Generation Open Source Framework for Deep Learning, In Proceedings of Workshop on Machine Learning Systems (LearningSys) in The Twenty-ninth Annual Conference on Neural Information Processing Systems (NIPS) (2015). 6 pages.
 [2] <https://www.wireshark.org>