

有線通信におけるネットワークの輻輳予測に 用いる特徴量に関する考察

理学専攻・情報科学コース 2040629 明石季利子 (指導教員: 小口正人)

1 はじめに

突然発生する通信障害は、大規模災害時による通信過多やDDos攻撃、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。TCPによるデータ転送において、既に輻輳制御アルゴリズムが実装されている。しかし、輻輳によるスループットの低下はネットワーク機器依存の要因の他に、ユーザの行動が原因となるようなものも含まれる。それに対処するには、ネットワーク機器のモニタリングを行って判断する従来の方法だけでは難しい。本研究では、ネットワークのトラフィックデータを用いて深層学習LSTMモデルによる輻輳の時系列予測を行うことで、なるべく早く輻輳の検出をすることを目指す。加えて、有線通信時のパケット情報から、輻輳が起きることを高確率で予測できる特徴量を検討する。

2 実験

本実験は、学習用のデータをiperf通信で取得して、LSTMモデルを使って予測を行い、評価する。学習用のデータはiperfの通信のみを行った実験1と、別の通信を行いながらiperf通信を行なったの2通りを用意した。

2.1 実験環境

実験用マシン1台をサーバ、5台をクライアントとしてiperfを用いたTCP通信を行い、送受信されたパケットを各マシンでキャプチャする(図1)。その際カーネルモニタ[1]を用いて通信時のcwndを取得する。TCP輻輳制御アルゴリズムはRenoとCUBICを用いた。




図 1: 実験環境

2.2 学習データ

入力データは $t-9$ 秒~ t 秒の 10 秒間に送受信したパケットから 1 秒おきに 3 つの特徴量 (パケット数, rwnd の値, cwnd の値) を導出したものとする。正解データは、時刻 $t+1$ 秒の輻輳状態を 0,1 で表した値とする。本実験の輻輳状態とは、重複 ACK・高速再転送・重複受信・ACK ロスによる再送パケットをマークしたものとする。実験 1 で使用した Reno の学習デー

タを図 2 に示す。




図 2: 学習データの一部

2.3 輻輳の予測結果

モデルの作成は、パケットデータの取得元をサーバ側 (ServerSide)・クライアント側 (ClientSide)・その両端 (BothEnds) の 3 パターンに分ける。また、特徴量の比較のため、パケット数・cwnd・rwnd・すべてを含む場合の 4 パターンに分け、全 12 種類の学習モデルを作成した。100 秒間のバリデーションデータを用いて輻輳予測を行なった結果を図 3 に示す。

3 性能評価

3.1 混合行列による評価

本実験では、学習モデルの評価のため混合行列を使用した。輻輳状態である「Positive」もしくはそうでない「Negative」の 2 クラスに分類する場合の混合行列の各要素を表 1 に示す。

表 1: 混合行列

実際予測	Positive	Negative
Positive	TP: 真陽性	FN: 偽陰性
Negative	FP: 偽陽性	TN: 真陰性

正解値と予測値の混合行列を基に、正解率・適合率・再現率・F 値を算出する式をそれぞれ以下に示す。適合率の値が大きいほど、誤検知が少なく、再現率の値

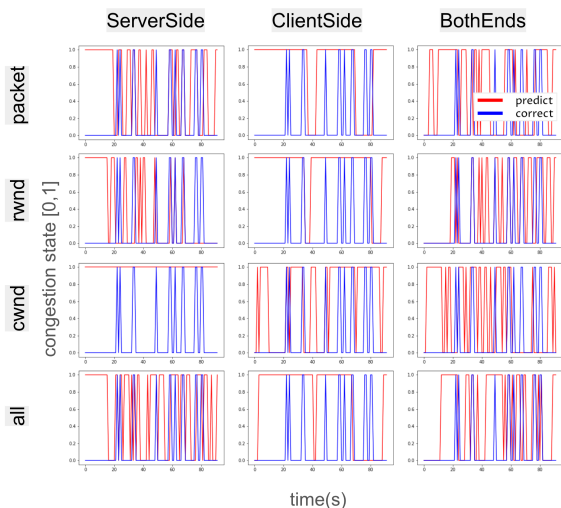


図 3: バリデーションデータの輻輳予測

が大きいほど、検知漏れが少ないと判断できる。

- 正解率 = $TP + TN / (TP + TN + FP + FN)$
- 適合率 = $TP / (TP + FP)$
- 再現率 = $TP / (TP + FN)$
- F 値 = $(2 \times \text{適合率} \times \text{再現率}) / (\text{適合率} + \text{再現率})$

3.2 評価結果

実験 1 の各モデルにおける 4 つの評価指標をグラフ化したものを図 4 に示す。

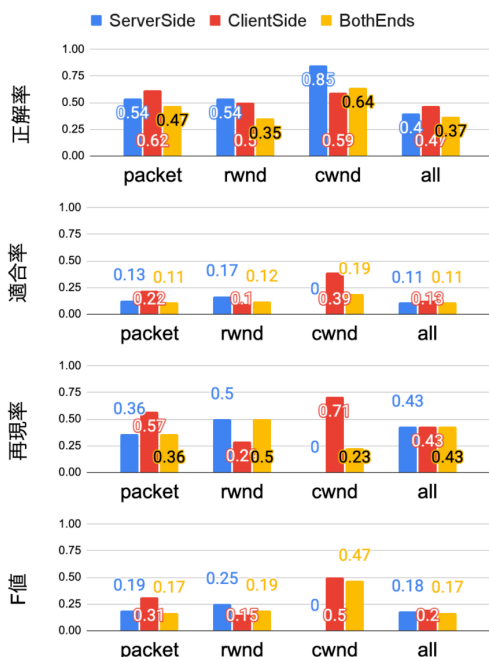


図 4: 学習モデルの性能評価

正解率が最も高いのは ServerSide・cwnd のモデルとなったが、適合率や再現率ともに 0 となっている (図 4)。バリデーションデータを用いて予測した結果 (図 3) を見ると、輻輳状態を予測しないことでそうでない状態を当てた数が増えるため、正解率を高くしている。これは予測モデルとして意味を成さない。再現

率、F 値どちらも、ClientSide・cwnd のモデルが高い値となった。

3.3 考察

iPerf 通信の実験において、ServerSide・cwnd を学習したモデルは、正解率が 85% と最も高い数値となった。ClientSide・cwnd のモデルは、再現率 71%、F 値 50% と他モデルに比べて最も高く、輻輳予測として評価が高いモデルであると言える。しかし、バリデーションデータを用いた輻輳の予測結果を見ると、輻輳が起きないことを予測し続けることで正解率を高めていたことがわかる。再現率が低く、偽陰性が高いため輻輳予測としては良くないモデルであると言える。また、輻輳が起きることを予測し続けることも予測として意味を成さないため、ある一定の正解率が担保される必要がある。

潜在的である輻輳発生を考慮すると、輻輳制御を行う通信事業者は、陰性の活動が誤って輻輳が発生したとして認識される「偽陽性」よりも輻輳が検知されない「偽陰性」に対してより敏感であると考えられる。

輻輳制御アルゴリズムの違いにおいて、CUBIC で取得した学習データは輻輳状態のマーク数が多かったため、学習させる陽性ラベルの数が多く、精度が安定した結果となった。陽性ラベルの数が多いため、モデルを作ることで正解率を上げることができると予想した。そのため、ファイルダウンロード時の iPerf 通信実験を行った。結果は、全体的に予測精度が向上した。陽性ラベルが多いデータを学習に活用すると予測精度が向上した。

4 まとめと今後の課題

4.1 結論

本研究は、輻輳の早期検知を目指し、ネットワークトラフィックデータを用いて深層学習モデル LSTM による輻輳の時系列予測を行った。輻輳が検知されない「偽陰性」を抑えることを評価軸とし、高確率で予測できる特徴量を検討した。通信条件を変えた実験 1・2 を通して、Reno では ClientSide・cwnd, rwnd, ServerSide・all のモデル、CUBIC では ClientSide・cwnd を含むモデルで高い予測精度が得られた。

4.2 今後の課題

輻輳が起きていないことを予測し続けることで正解率を高めてしまう結果を踏まえて、再現率が高いモデルの正解率をある一定の精度高めることでより最適化されたモデルを作成できると考えている。そのため、良性ラベルの精度が 50% 以上であることを条件に、予測精度を最適化することを目標としてモデルの実験を行いたい。加えて、学習するトラフィックデータのその他の特徴量を追加して比較実験を行うことで、輻輳検知と関連性が高い特徴量を発見したい。

参考文献

- [1] Kaori Miki, Saneyasu Yamaguchi, and Masato Oguchi. Kernel monitor of transport layer developed for android working on mobile phone terminals. In *Tenth International Conference on Networks (ICN)*, 2011.