

# 深層学習のLSTMを用いた無線LAN通信時のパケット解析とスループットに基づく輻輳の予測

山本 葵<sup>†</sup>山口 実靖<sup>††</sup>神山 剛<sup>†††</sup>小口 正人<sup>†</sup><sup>†</sup>お茶の水女子大学<sup>††</sup>工学院大学<sup>†††</sup>九州大学

## 1. はじめに

近年、気軽に動画やゲームなどのデータ通信を楽しむことが出来るようになり、大容量かつ高速な通信に対する需要は増大している。しかし有線接続に比べ低帯域かつノイズの多い無線接続においては、輻輳が発生してしまうという問題も生じている。本研究では輻輳発生前に制御を加え無線LAN APの輻輳を回避することを最終目的とし、本稿では目的達成のため輻輳の予測を行う。

## 2. 研究背景

世界中に増加し続けるスマートフォンやタブレット端末は大容量データ通信を容易にし、それに伴い無線LANへの負荷は増大すると考えられる。解決法としては、高速通信の規格化があり、可用帯域の増加や伝送速度の向上があるが、規格が広く普及するには時間がかかり、実際街中では狭い帯域を取り合っているのが現状である。

よって輻輳を早期検出しトラフィックを制御する必要がある。

## 3. 関連研究

### 3.1 カーネルモニタ

先行研究で開発されたカーネルモニタは、通常見ることができないカーネル内部のTCPパラメータをモニタできるツールである。このツールをAndroidに組み込むことで、輻輳ウィンドウやRTTなどの変化を記録する。本研究は輻輳を回避するために制御を行うことを目標としている点で関連研究を継承しているが、輻輳が起こった後に制御を加える関連研究に対し、輻輳が起こることを予測して輻輳が起こる前に制御を加えることを目標としている点で異なる。

## 4. 深層学習

本研究では深層学習を行う。深層学習は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機械学習を実装するための1つの手法である。LSTMは時系列データに対するモデルである。大きな特徴は文章などの長い依存関係にあるデータも覚えておくことができる長期依存が可能であるということである。

本研究は時系列データであるパケットの解析であるため、このLSTMをモデルとした深層学習を行う。

## 5. 正解データの検討

本章では深層学習をする際の正解データをどのように設定するか実験を行い決定する。先行研究にて開発された

Congestion Prediction Based on Throughput and Wi-Fi Packet Analysis Using LSTM of Deep Learning

<sup>†</sup> Aoi Yamamoto, <sup>††</sup> Saneyasu Yamaguchi, <sup>†††</sup> Takeshi Kamiyama, <sup>†</sup> Masato Oguchi

Ochanomizu University (<sup>†</sup>), Kogakuin University (<sup>††</sup>), Kyushu University (<sup>†††</sup>)

カーネルモニタを導入した端末を用いて通信を行い、通信時のTCPパラメータとiperfを使用して測定した通信速度であるスループットを取得する。輻輳の発生を観察するために70秒間パラメータを取得し、0-20秒はパケットを送信せず、20秒付近で全ての端末から一斉にiperfによりサーバにパケットを送信した。図1は端末6台の輻輳ウィンドウ(CWND)の振る舞いを測定した結果、図2は各端末のスループットを振る舞いを測定した結果とそのスループットを合計した結果である。比較してみると、CWND値が小さくなり輻輳を検知したと思われる箇所はスループットも減少している。また各端末のスループットを合計することで、複数の端末で通信するとき起こる1部の端末が帯域を占領してしまう場合においても、接続しているAPが混雑しているかどうか判断できるのではないかと考える。そのため輻輳の発生を表す正解データとしてスループットの合計値を用いる。

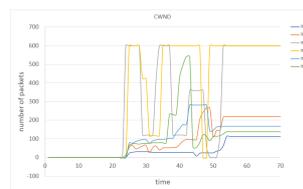


図1: CWNDの推移 (6台通信)

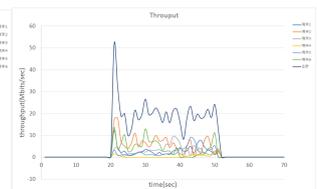


図2: スループットの推移 (6台通信)

## 6. 実験

本章では端末によるデータ通信を行なった時に深層学習を用いて輻輳が予測できるか評価実験を行なった。使用した深層学習用フレームワークはChaier[4]である。実験環境は図3である。1台のAPに接続した複数台の端末からiperf[5]によって、データをサーバに送信する。

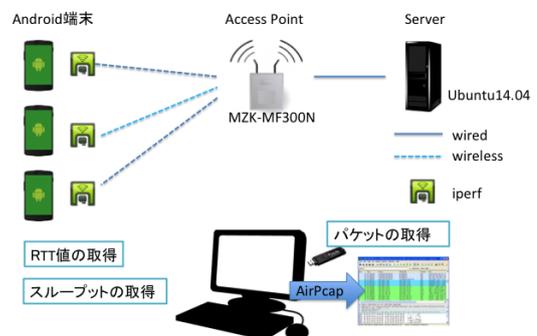


図3: 実験環境

### 6.1 学習に用いるデータセット

入力データとして無線LAN AP周辺のパケットを使用する。パケットを数値化し、さらにカーネルモニタから取得したCWND値を加えたものを入力データとした。正解データには5.章よりスループットの合計値である。データ

セットは図4である。適切なデータ形式に加工し、LSTMモデルを用いた深層学習をおこなう。

入力データ	正解データ
1秒間 [length_sequence_number ... cwnd1 ...cwnd N] (1/パケット+cwnd)	スループット
[length_sequence_number ... cwnd1 ...cwnd N]	
...	
[length_sequence_number ... cwnd1 ...cwnd N]	

図4: データセット

### 6.2 学習

2台通信時のデータ, 6台通信時のデータの2つのデータセットを用いてそれぞれ学習を行なった。6台の端末を用いて通信を行い, 70秒間のデータを取得した。0-20秒,50-70秒はパケットを送信せず, 20-50秒でiperfを用いて通信する。この70秒間で取得した情報をデータセットとしt秒の入力データからt秒のスループットを予測する学習を行った。

### 6.3 学習データによる予測結果

図5は70秒の学習用データを学習させたモデルに再び同じ70秒の学習用データを入力データとして与えたものである。オレンジの線が正解のRTT値, 青の線が予測した値である。精度よく学習ができていることがわかる。

### 6.4 テストデータによる予測結果

学習の汎化能力を検証するためテストデータによる検証を行う。テストデータは新規に作成する。6台の端末を用いて通信を行い, 50秒間のデータを取得してデータセットとした。0-10秒,30-50秒はパケットを送信せず, 10-30秒でiperfを用いて通信した。学習に用いたデータとは違うデータをモデルに入力することで汎化能力を検証する。

結果は図6となった。10秒付近に大きくスループット値が上がる箇所は数秒の誤差で予測ができおり, また30秒でスループット値が大幅に減少する箇所も予測も5秒ほどの誤差で減少する予測ができている。

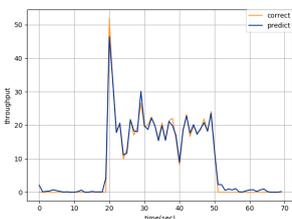


図5: 学習データによる予測結果 (6台通信)

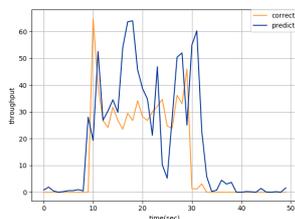


図6: テストデータによる予測結果 (6台通信)

### 6.5 数秒先の予測

6.2章から6.4章での実験ではt秒までの入力データからt秒の正解データであるスループットを予測できるか検証した。しかし制御を目的とした本研究では, t秒までの入力データから数秒先の正解データを予測し, 輻輳を発見する必要がある。そこでt秒までの入力データからt+5秒の正解データを予測する実験をした。学習に用いたデータは6.2章の6台通信時のデータセットである。

結果は図7と図8である。5秒先の予測では, 学習データによる予測はある程度精度は良いが, テストデータは全く予測できていないという結果になった。一斉に通信することより, 今回の学習では輻輳が起こる予兆が一切なかったためと考えられる。

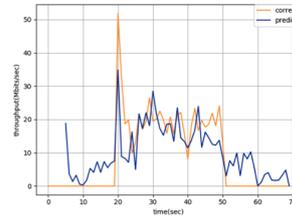


図7: 学習データによる予測結果 (t+5)

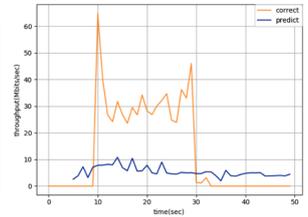


図8: テストデータによる予測結果 (t+5)

## 7. まとめと今後の課題

本研究では, APに接続する端末が通信を行い, 輻輳発生前に制御を行うことを目標とし, その前段階として輻輳の早期発見のために深層学習を用いて予測を行なった。

学習データによる予測結果より, 特徴を良く学習できていることがわかった。テストデータによる検証でもある程度の誤差で予測できた。

今後の課題としてはあらゆる状況においてのデータを用いて十分に学習をさせ, また端末の台数の変更や端末が一斉に通信を行なった場合だけでなく, ランダムに通信を行なっている場合においても精度よく予測ができるように学習を行って行きたい。

また今後輻輳制御を行っていくことを見据え, 計算時間も考慮に入れて実験を行って行きたい。

## 謝辞

本研究は一部, JST CREST JPMJCR1503の支援を受けたものである。

## 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," Proc. ICN2011, pp.297-302, January 2011.
- [2] Ai Hayakawa, Saneyasu Yamaguchi, Masato Oguchi: "Reducing the TCP ACK Packet Backlog at the WLAN Access Point," Proc. ACM IMCOM2015, 5-4, January 2015.
- [3] Ayumi Shimada and Masato Oguchi: "A Study of Android Tables Performance," Proc.DEIM2017,H2-3,March 2017
- [4] Chainer,Framework for Neural Networks, <https://chainer.org/>
- [5] Iperf For Android Project in Distributed Systems, <http://www.cs.technion.ac.il/sakogan/DSL/2011/projects/iperf/index.html>