

## LSTM を用いた有線通信における帯域予測手法の提案と評価

小山内 遥香<sup>†</sup>中尾 彰宏<sup>‡</sup>山本 周<sup>‡</sup>山口 実靖<sup>§</sup>小口 正人<sup>†</sup><sup>†</sup>お茶の水女子大学<sup>‡</sup>東京大学<sup>§</sup>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。

従来は、通信障害の発生を検知したら経路やシステムの切り替えを行うなど、通信障害が起こってから対処する仕組みがとられてきた。しかし、通信障害が起きてからの対処では復旧に時間やコストがかかり対応が手遅れである場合が多い。そのため、トラフィック変動を予測し、通信障害が発生する前に対処することができれば最も効率が良いと考えられる。

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。

本研究では、深層学習のモデルの一種である Long short-term memory(LSTM) を用いて、トラフィックのモニタリングデータのみからトラフィック変動を予測するための手法の提案および作成した予測モデルの性能評価を行う。

## 2. 深層学習

深層学習とは、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。近年では、深層学習を用いてリアルタイムな人口データから 30 分先のタクシーの需要を 92.9%の精度で予測し、売り上げの増加に貢献するなど、社会に多大な利益をもたらしている。

現在、数多くの深層学習のためのフレームワークが提供されており、本研究では Preferred Networks 社が開発した Chainer[1] を使用している。

## 2.1 LSTM

LSTM は、時系列データの学習に用いられるネットワークで、以前に計算された情報を記憶することができる。時系列データの学習に用いられるネットワークには LSTM の他に Recurrent Neural Network(RNN) が存在するが、LSTM は RNN が持つ勾配の消失、発散などの問題を解決するために RNN を改良したネットワークである。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 では扱うことができなかった長期依存を扱えるようになっている (図 1)。

本研究で扱うパケットデータは時系列データであり、比較的長いパターンを学習する必要があるため、LSTM を用いてネットワークトラフィックの予測を行なっている。

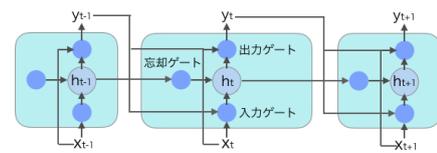


図 1: LSTM のネットワーク図

## 3. 実験

## 3.1 実験環境

本実験では、3 台の実験用マシンを使用し、1 台をサーバ、2 台をクライアントとして iPerf を用いてトラフィック発生を行う。本実験では、サーバ・クライアント間にダミーネットワークを挟み、遅延を 100ms、サーバ・ダミーネットワーク間の帯域を 70Mbps とした (図 2)。

サーバとクライアントは TCP で通信し、送受信されたパケットをサーバ側でキャプチャした。キャプチャしたデータを用いて学習モデルを作成し、学習データとは異なるバリデーションデータを用いて帯域予測を行なった。サーバ・クライアント間での TCP 輻輳制御アルゴリズムは Reno を用いた。

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 (3 秒移動平均)

Proposal and Evaluation of Bandwidth Prediction Method in Wired Network by LSTM

Haruka Osanai<sup>†</sup>

Akihiro Nakao<sup>‡</sup>

Shu Yamamoto<sup>‡</sup>

Saneyasu Yamaguchi<sup>§</sup>

Masato Oguchi<sup>†</sup>

<sup>†</sup>Ochanomizu University

<sup>‡</sup>University of Tokyo

<sup>§</sup>Kogakuin University

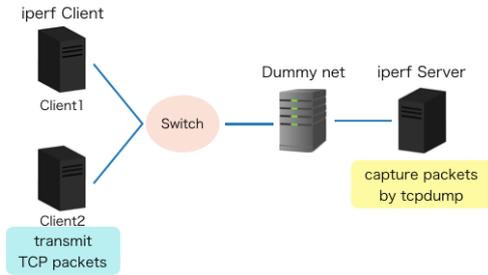


図 2: 実験環境

正解データは時刻  $t+1$  秒に届いたパケット数 (3 秒移動平均) を 0~1 に正規化した値である。

### 3.2 学習モデルによるバリデーションデータの予測

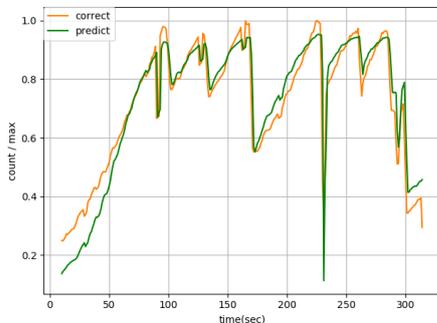


図 3: バリデーション 1 の予測結果

作成した学習モデルにバリデーションデータを入力したところ、目視においてはパケット数変動の傾向をおおまかに予測できていることがわかる (図 3)。予測性能については後述の評価指標を用いた性能評価を行う。

### 3.3 提案手法の性能評価

送受信パケット数の変動などの時系列データの予測において、増加し続けるなど同じ変動が続く場合、直前の変動を繰り返すことである程度高い精度で予測ができてしまうことが考えられる。本研究ではこの直前の変動を繰り返すモデルを repeat と呼ぶこととする。

表 1 は、送受信パケット数の変動で起こる変動の種類を表したものである。repeat は増減が変化する箇所を予測することができないため、変動 2 と変動 3 は予測することができず、変動の方向が変わらない変動 1 と変動 4 のみ予測することができる。

評価には、正解値の増加・減少をどの程度予測できるかを表す一致率を指標として使用する [2]。repeat と作成した学習モデルを用いて一致率 (MATCH) を算出し、予測できた変動の種類の内訳を用いて、それぞれのモデルの予測精度の比較を行う。

図 4 では、repeat よりも、提案手法の MATCH の値が上回る結果となった。このほか 2 種のバリデーションデータを用いて MATCH を算出した結果も図 4 と同様の結果

表 1: 変動の種類

直前の変動 \ 現在の変動	増加	減少
	増加	変動 1
減少	変動 3	変動 4

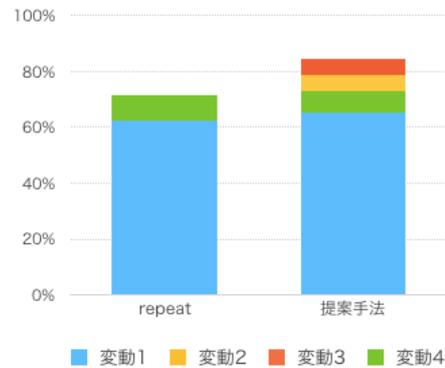


図 4: バリデーションデータを用いた各モデルの MATCH

なり、repeat よりも提案手法の方が精度よく予測できていることがわかった。

## 4. まとめと今後の課題

本研究では、深層学習モデル LSTM を用いて帯域予測を行う学習モデルの作成と予測性能の評価を行なった。MATCH の観点から他モデルとの性能比較を行うことにより、他モデルでは予測できない帯域の変動も提案手法では予測が可能であり予測性能が向上することが示された。今後の課題として、災害時や DDoS 攻撃時などに実際に収集されたデータセットを用いた学習モデルの作成を検討している。

## 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] 南正太郎” LSTM-RNN を用いたイベント考慮後の株価時系列予測”, 第 19 回人工知能学会金融情報学研究会 (SIG-FIN 2017), 2017 年 10 月.