

# ネットワークトラフィック変動のRNNによる予測

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 〒112-8610 東京都文京区大塚 2-1-1

<sup>††</sup> 東京大学 〒113-8654 東京都文京区本郷 7-3-1

<sup>†††</sup> 工学院大学 〒163-8677 東京都新宿区西新宿 1-24-2

E-mail: <sup>†</sup>{g1420514,oguchi}@is.ocha.ac.jp, <sup>††</sup>nakao@nakao-lab.org, shu@iii.u-tokyo.ac.jp,  
<sup>†††</sup>sane@cc.kogakuin.ac.jp

あらまし 大規模災害時は電話やメールなどの通信手段が利用可能であることが重要である。しかし、このような災害時には平常時の数十倍のトラフィックが発生し輻輳状態になってしまう可能性がある。そのため、通信障害を効率的に検知し対処する必要がある。先行研究では、SNS 情報の解析結果に基づいてトラフィックの制御を自動的に行うシステムが提案、実装されている。本研究では、ネットワークのトラフィック変動時の輻輳状態を検知するために、深層学習のモデルの一種である RNN を用いてトラフィックを解析し輻輳状態に関する情報を抽出する手法を提案する。そして、ネットワークトラフィックの変動予測の性能評価を行い、その性能に関して考察する。

キーワード 深層学習, RNN, ネットワークトラフィック, 変動予測

## Prediction of Variation in Network Traffic by RNN

Haruka OSANAI<sup>†</sup>, Akihiro NAKAO<sup>††</sup>, Shu YAMAMOTO<sup>††</sup>, Saneyasu YAMAGUCHI<sup>†††</sup>, and  
Masato OGUCHI<sup>†</sup>

<sup>†</sup> Ochanomizu University 2-1-1 Otsuka, Bunkyo-ku, Tokyo 112-8610, Japan

<sup>††</sup> University of Tokyo 7-3-1-1 Hongo, Bunkyo-ku, Tokyo 113-8654, Japan

<sup>†††</sup> Kogakuin University 1-24-2 Nishi-shinjuku, Shinjuku-ku, Tokyo 163-8677, Japan

E-mail: <sup>†</sup>{g1420514,oguchi}@is.ocha.ac.jp, <sup>††</sup>nakao@nakao-lab.org, shu@iii.u-tokyo.ac.jp,  
<sup>†††</sup>sane@cc.kogakuin.ac.jp

### 1. はじめに

近年、各地で大規模な災害が多発している。大規模災害時には、被災状況や安否確認、避難経路等の情報を得ることで避難や救助活動が適切に行われる。また、通信は現在、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おり、突然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。そのため、通話やメールなどの通信による情報伝達が可能であることが非常に重要である。しかし、このような災害時には、被災地域では、被災地内外から通信ネットワークの処理能力を大幅に超える通信が集中し輻輳状態になってしまうため、通信がほとんどできなくなる可能性がある。そのため、通信障害を早期に検知し、効率的に対処する必要がある。

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。

本研究では、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状の情報を抽出することで、ネットワークトラフィックが大きく変動するときの兆候を掴む手法を提案する。

### 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。これを用いることにより、データの特徴をより深いレベルで学習することができる。

ニューラルネットワークとは、生物の脳の神経回路をモデルとしたアルゴリズムである。入力層、隠れ層、出力層を持ち、各層は複数のノードがエッジで結ばれる構造となっており、各エッジはそれぞれ重みを持っている。出力層からの出力と正解データの誤差を計算し、それを出力層から入力層へ逆に伝播させることにより重みを更新して学習を行う。

ニューラルネットワークは、画像データを扱うのに有効なもの、時系列データを扱うのに有効なもの、クラスタリングや次元削減を行うものなどがあり、それぞれ扱うデータの特徴によって学習結果の精度が変わることがある。

近年では、深層学習を用いて心疾患患者の医療情報を解析を行い、再入院のリスクを予測し、従来基準の2倍以上の患者の再入院の防止や医療費の低減を実現したり、リアルタイムな人口データを用いて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。

## 2.1 RNN

RNN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(図1)。しかし、系列が長くなり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、実際には2,3ステップ前までの記憶しか保持することができない。

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)であり、LSTMはRNNの一種である。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2)。

入力ゲートと出力ゲートは、必要な誤差信号だけが適切に伝播するようにゲートの開閉を行うために導入され、忘却ゲートは、入力の系列パターンが変わったときに、一度学習した内容を忘れてノードの状態を一気に初期化するために導入された。

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、長期の時系列データの学習を行うのに有効である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 RNNのネットワーク図




図2 LSTMのネットワーク図

## 3. 関連研究

深層学習を用いて、株価変動や降水量の予測を行う手法が存在する[1][2][3]。

[1]では、LSTMを用いて株価の予測を行う手法が提案されている。この研究はLSTMを用いて時系列データの学習、予測を行なっている点で、本研究と類似している。

[2]では、深層学習のモデルであるCNNを用いて日経平均株価の騰落の予測を行う手法を提案している。CNNは、視野の特徴抽出の仕組みをモデル化したもので、画像識別を行うのに有効である。畳み込み層によって特徴量を抽出し、プーリング層によってノイズ処理を行うことによって局所ごとに特徴をまとめ、画像の特徴を学習する。株価データは時系列データであるため、株価データの予測においては時系列データを扱うのに有効なRNNやLSTMを使った予測手法が盛んであり、それと比較してCNNを用いた予測は少ない。

[3]では、CNNとLSTMを組み合わせたConvolutional LSTM(ConvLSTM)を用いて降水量の予測を行なっている。ConvLSTMは、時系列性と空間性の両方を持つ時空間データの予測に用いられるモデルである。降水量は、位置情報を持った時系列データで時空間データであるため、ConvLSTMを用いた手法は精度の高い予測を実現できる手法である。

本研究は、予測対象としてネットワークトラフィックを扱っており、また、将来的には予測結果を用いてネットワークの制御を行うことを目指している。

また、ネットワーク障害を検知するために、SNSによる集合知を用いた研究が存在する。[4]では、災害時に発生する通信障害を早期に検知する手法としてTwitterのツイート解析を用い、解析結果に基づいて自動的にネットワーク制御を行うシステムを構築している。ネットワーク障害検知システムのリアルタイム処理を行うことにより、通信障害の早期検知を実現している。この研究は、通信障害を検知する手法としてSNS情報を用いている点で、深層学習を使用して障害検知を行うことを目指す本研究とは異なる。

## 4. 関連技術

### 4.1 Chainer

Chainer[5]とは、深層学習を行うためのライブラリである。Chainerは、Pythonの制御構文をそのまま使用できるため単純なネットワーク構成から複雑なネットワーク構成まで直感的に記述できる。ネットワーク構築と学習を同時に行う方式がとられており、幅広い種類のニューラルネットワークに柔軟に対応できるため、Convolutional Neural Network(CNN)、RNNなど、様々なタイプのニューラルネットワークをシンプルに記述できる。また、GPUを利用して高速な計算を行うことが可能であり、計算が長時間になりがちな深層学習を効率良く行えるようになっている。

本研究ではChainerを使用して深層学習を行っている。

### 4.2 Wireshark

Wireshark[6]とは、ネットワークアナライザソフトウェアであり、ネットワークを流れるパケットをキャプチャして解析、表

示するソフトウェアである。ネットワークを流れるパケットをリアルタイムに解析でき、解析可能なプロトコルは 800 以上と解析性能が非常に高い。PC やサーバが送受信するパケットをすべてキャプチャして可視化できるため、ネットワークにおける問題が発生した場合、問題を解決するのに役立つソフトウェアである。Wireshark はオープンソースで開発されている。

## 5. 実験

### 5.1 実験概要

学習を行う際の入力データと正解データの作成方法について説明する。正解データは時刻  $t+1$  秒の前 4 秒と後 5 秒の間に届いたパケット数の平均を正規化したものである。つまり、時刻  $t-3$  秒～ $t+6$  秒の 10 秒間に届いたパケット数の平均を正規化した値である。10 秒間のパケット数の平均とした理由としては、パケット数の詳細な予測を行うことは困難であるが、ネットワークトラフィックのおおまかな変動が予測できれば十分役に立つためである。また、その値を正規化したものを正解データとしたのは、学習効率を上げるためである。

入力データにはパケット情報から導出した 18 種の特徴量を用いており、詳細は以下である。

- パケット送受信時刻
- プロトコル名 (TCP, UDP, ARP など)
- パケットサイズ
- 送信元 IP アドレス
- 宛先 IP アドレス
- 送信元ポート番号
- 宛先ポート番号
- TCP ヘッダのフラグ 10 個

– res, ns, cwr, ecn, urg, ack, push, reset, syn, fin

- ウィンドウサイズ

$t-9$ ～ $t$  秒の 10 秒間に届いたパケットそれぞれの上記 18 種の特徴量と正解データを組にして学習を行う。

表 1 実験で用いた計算機の性能

OS	Ubuntu 14.04.4LTS
CPU	Intel Core i7-6700K CPU @4.00GHz
GPU	GeForce GTX 1080
Memory	32Gbyte

実験で用いた計算機の性能を表 1 に示す。

### 5.2 学習

Wireshark を使い、研究室 LAN 内においてブラウザで動画サイトをひとつだけ開き、異なる 30 秒間の動画 4 つを自動で連続再生したときのパケットをキャプチャした。図 3 はそのパケット数を 1 秒ごとにプロットしたグラフであり、青いグラフが元データ、オレンジのグラフが移動平均をとった正解データである。今回は予備実験として、このデータを用いて学習を行い予測モデルを作成した。

図 3 のデータを用いて学習を行う。epoch 数は 700、隠れ層の数は 49 としている。

予測モデルに学習データを入力し予測した結果、正解データと予測結果の平均二乗誤差が 0.03169 となり、正解データと近




図 3 学習データ




図 4 学習データを用いた予測

い値が予測されており、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)。

### 5.3 性能評価

性能評価では、2 つのテストを行なった。

- テスト 1: 学習データを取得したときと同じ環境で、学習データとは異なる 4 つの 30 秒間の動画を自動で連続再生しパケットを取得 (図 5)

- テスト 2: 動画サイトを変更し、30 秒間の動画 4 つを自動で連続再生しパケットを取得 (図 6)

図 7 はテスト 1 の予測結果である。正解データと予測結果の平均二乗誤差は 0.10636 となり、学習データと比較すると精度が下がるが、正解データのパケット数が増加する約 10 秒、45 秒、80 秒、110 秒のとき、予測結果のパケット数も増加しており、パケット数が大幅に変化する箇所は概ね予測できていることがわかる。

図 8 はテスト 2 の予測結果である。パケット数の増加、減少のタイミングがずれてしまい、平均二乗誤差が 0.24920 と誤差が大きくなっている。しかし、一度パケット数が増加すると、大幅に減少するのは約 15～20 秒後で正解データの増減の間隔とほぼ一致しており、増加や減少の差がテスト 1 の結果よりも




図5 テストデータ 1




図8 テスト 2 の予測結果




図6 テストデータ 2




図7 テスト 1 の予測結果

明確に予測できている。

また、テスト 1 とテスト 2 の結果より、確立しているコネクションがひとつの場合は使用するアプリケーションを変更しても予測が可能であることがわかる。

それぞれの予測結果の平均二乗誤差を表 2 にまとめる。テス

ト 2 の誤差が、学習データを入力として用いたときの約 7.8 倍、テスト 1 の約 2.3 倍と非常に大きくなっているのは正解データと予測にずれがあるためであり、正解データと予測のずれが解消できれば誤差が減少すると考えられる。

表 2 平均二乗誤差

学習データ	テスト 1	テスト 2
0.03169	0.10636	0.24920

## 6. まとめと今後の課題

深層学習のモデルである 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。今回は予備実験として、動画サイトで動画を再生したパケットデータを学習データとして予測を行うと、トラフィック変動をある程度予測することができ、学習データの特徴をうまく学習できていることがわかった。次に、テストデータを用いて性能評価を行なった結果、学習データを用いたときと比較すると精度が下がってしまうが、パケット数が増減するタイミングはある程度予測できた。

今後はまず、テスト 2 において正解データと予測の結果がずれてしまう原因についての調査、パラメータのチューニング、学習データ量や使用する特徴量の増加などを行い、予測性能の向上を目指す。学習において精度に影響を与える特徴量についての調査を行う。これにより、より高度な障害検知やネットワーク制御が可能になると考えられる。

また、予測結果を用いた障害検知システムの構築や、ネットワーク制御の手法を検討する。また、実際のトラフィック異状時でも現在の予測システムが利用可能か確認するために、輻輳発生時など実際のデータを用いた学習や予測の実験も行う。

## 謝 辞

本研究は一部、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。

## 文 献

- [1] 松井藤五郎, 汐月智也” LSTM を用いた株価変動予測”, 第 31 回人工知能学会全国大会 (JSAI 2017), 2D3-OS-19a-2 (2017).
- [2] 宮崎邦洋, 松尾豊” 深層学習を用いた株価予測の分析”, 第 31 回人工知能学会全国大会 (JSAI 2017), 2D3-OS-19a-3 (2017).
- [3] 林政行, Rafik Hadfi, 伊藤孝行” 深層学習を用いたマルチモーダル学習による降水量予測”, 情報処理学会全国大会講演論文集, 78rd,p.2.369-2.370, (2016).
- [4] 丸千尋, 榎美紀, 中尾彰宏, 山本周, 山口実靖, 小口正人” 大規模災害時における SNS による集合知に基づいたネットワークの QoE 制御”, マルチメディア, 分散, 協調とモバイル (DI-COMO2016) シンポジウム, pp.1418-1426, 2016 年 7 月.
- [5] 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.
- [6] <https://www.wireshark.org>