

複数の変動要因情報の学習に基づく WLAN スループットの予測
WLAN Throughput Prediction Using Deep Learning with Multiple Factors

土屋 文彦[†] 菅 宣理^{‡, †} 雨車 和憲[§]
Yoshihiko Tsuchiya Norisato Suga Kazunori Uruma
矢野 一人[†] 鈴木 義規[†] 藤沢 匡哉[†]
Kazuto Yano Yoshinori Suzuki Masaya Fujisawa

あらまし

無線LANスループットを予測し通信を制御することで、周波数資源を有効利用する技術が検討されている。既存のスループット予測手法では過去に観測したスループットの変動を深層学習により学習することで将来のスループットを予測するが、スループットの変動は受信信号強度 (RSS: Received Signal Strength) やチャネル占有率 (COR: Channel Occupancy Ratio) の変動等、複数の要因があり、スループットのみでの学習では予測精度に限界がある。そこで本研究では、スループットの変動要因となる RSS と COR を併せて学習することで予測精度の向上を目指す。複数のニューラルネットワークに対して、スループットのみとスループット・RSS・COR で学習させて予測精度を比較し、ネットワークの構造によらず RSS・COR を用いることで精度が向上することを確認した。

1. まえがき

製造や物流の現場では生産性を向上させるために様々な IoT 機器を用いたアプリケーションが利用され始めている [1]。断線のリスクや再配線のコストの観点からこれらの IoT 機器を無線 LAN (WLAN) によりネットワークに接続することが期待されているが、工場や倉庫のような物体が多く入り組んだ空間では電波の干渉や反射、機器等の移動による無線環境の変動により通信品質が劣化するため、高い通信品質が求められるアプリケーションに対しては所要の通信品質を満たせない状況が発生し得る。そのため、スループット等の通信品質指標の予測することで通信品質の劣化が生じる前に適切な制御を行うことが重要となる。例えば、通信品質の低下を予測することで、事前に利用チャネルを変更し低下を防止することができる。このように、通信品質の予測とそれを元にした制御によって、通信状況に合わせた周波数の有効利用が可能となる。これには高精度な通信品質予測が必要となる。

通信品質指標であるスループットについて、過去の値を基にニューラルネットワークを用いて予測する手法 [2] が示されている。[2]では、畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) が用いられ、一定長の過去のスループット情報を利用し、一定時刻先のスループットの値を予測する。予測値をいくつかのラベルに分類し、分類問題としてそのラベルを予測し、スループットの値を予測できるように学習が行なわれている。大きさの異なる数種類の CNN で学習と予測が行われ、どのネットワークでも同様な予測精度となり、比較的小規模のネットワークでも一定の予測精度が示されている。一方で、スループットは無線端末の移動に伴う伝送レートの変動や同一無線チャネル内の端末数の増減、印加されるトラフィック量の変動等の様々な要因から影響を受ける。したがって、[2]のように過去に観測したスループット値のみで学習を行う場合、スループット変動の要因 (RSS と COR の変動) の区別ができず、予測精度に限界があると考えられる。

本研究ではスループットの変動要因となる複数の情報を利用した予測手法を提案する。提案手法では、スループットのほかに、その変動要因となる RSS と COR を併せて学習することでより高精度なスループットの予測を実現する。シミュレーションデータを用いてネットワークの学習を行い予測誤差の比較をすることで、複数情報を利用し予測精度が向上することを示す。さらに、複数のニューラルネットワークで同様の比較を行い、ネットワークの種類によらず精度の向上が見込めることを示す。

本論文の構成はまず 2 で、本研究で用いる代表的な深層学習手法を紹介し、3 で本論文において提案する手法について説明する。4 でシミュレーションデータを用いた数値実験について説明し、最後に結論を述べる。

本論文の構成はまず 2 で、本研究で用いる代表的な深層学習手法を紹介し、3 で本論文において提案する手法について説明する。4 でシミュレーションデータを用いた数値実験について説明し、最後に結論を述べる。

2. 深層学習

2.1 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (CNN) は、畳み込み演算を行う層で構成されたネットワークである。CNN は 2 次元データなどの並びに意味のあるデータのパターン抽出に秀でており、画像データに対して広く用いられているネットワークである [3]。一方で時系列データに対しても、1 次元畳み込みで構成された CNN が利用されることがある。

2.2 再帰型ニューラルネットワーク

再帰型ニューラルネットワーク (RNN: Recurrent Neural Network) は、ニューラルネットワークを拡張し再帰構造を持たせたネットワークである [4]。再帰構造によって時系列データのような連続した並びのデータに適したネットワークとなっている。しかし、再帰構造による多層化が勾配消失や勾配爆発を引き起こし、長時間にわたるデータの関係をとらえることが困難であるという問題がある。

[†] 東京理科大学 〒125-8585 東京都葛飾区新宿 6-3-1
Tokyo University of Science, 6-3-1, Nijuku, Katsushika,
Tokyo, 125-8585 Japan

[‡] ATR 波動工学研究所 〒619-0288 京都府相楽郡精華町光台 2-2-2
ATR Wave Engineering Laboratories, 2-2-2,
Hikaridai, Seika, Souraku, Kyoto, 619-0288 Japan

[§] 工学院大学 〒163-8677 東京都新宿区西新宿 1-24-2
Kogakuin University, 1-24-2, Nishishinjuku, Shinjuku,
Tokyo, 163-8677 Japan

2.3 長・短期記憶

長・短期記憶 (LSTM: Long Short-Term Memory) は、RNN を改良したモデルである[4]。RNN で問題となっていた勾配消失を抑える、ゲートとメモリーセルと呼ばれる構造が組み込まれている。ゲートは過去の信号を減衰させ情報する忘却する役割がある。メモリーセルは過去の時刻の情報を次の時刻へと送り、情報を保持する役割を担っている。これらの構造によって、長期的なデータに対しても特徴を捉えることが可能となっている。

3. 提案手法

本研究では、予測精度が向上することを期待して、スループットの予測に際して複数の情報を併せて学習及び予測に用いることを提案する。ここで、複数情報として RSS と COR を用いる。RSS は端末が受信した電波の強度を示しており、アクセスポイントと端末間の距離によって変動する。また、COR はあるチャンネルを利用する割合であり、同チャンネルを利用する端末数や、やり取りするデータの大きさによって変動する。COR が低い値をとる場合は、RSS の値によらず十分な量の情報の送信が可能のため、スループットは変動しない。一方で、COR が高い値をとる場合は、送信できる時間が限られるため、スループットは RSS によって決まる物理層の伝送レートの影響を受けて値が変動する。したがって、スループットを高精度に予測するためには、RSS 及び COR の変動パターンを学習する必要がある。無線端末に特定の移動パターンがあり、それに連動した RSS の変動パターンがある場合を考える。このとき、スループットのみで学習すると、COR の値によっては RSS の影響が現れないため、適切な学習が行えないと考えられる。以上より提案手法では、スループットと併せて RSS・COR を同時に学習する。

次に、予測モデルと利用データについて説明する。本研究では、過去 T サンプルを入力としたときに、次の 1 サンプルのスループットを予測値として出力するモデルを想定する。したがって、スループットのみを入力としたモデル

では T 次元のデータで、スループット・RSS・COR を入力としたモデル (提案手法) では $3T$ 次元のデータとなる。また、データはそれぞれスケールが異なっており、データのスケールを操作せずに用いると学習が進行しないため、学習時には各データを標準化する。

次に、学習率について説明する。予測モデルの学習では、学習に従って学習率を変動させる。学習率とは勾配降下法における 1 ステップでの移動距離の大きさを決定するパラメータである。学習率を大きく設定すると 1 ステップの移動距離が大きくなり、誤差関数の形状を捉えられない。一方、学習率を小さく設定すると学習速度の低下や学習が進行しないといった問題がある。また、固定の学習率とした場合は、学習の途中で誤差が増加してしまうなどの問題が起きる。これらの問題に対し、学習を進めるための様々な学習率の設定法が考案されている。ここでは学習の停滞に従って学習率を低下させる方法をとる。まず、学習の始めはステップの移動距離を大きくすることで局所最適解へ近づける。しかし、一般に大きな学習率で学習を続けると、やがて誤差が減少しなくなる。そこで、誤差の減少が停止した時点で学習率を低下させることで、ステップの移動距離が小さくなり、再び誤差が低下することが期待できる。以上より、すべてのモデルに対し、初期学習率は大きな値に設定し、検証データでの誤差の改善がない状態で一定のエポックが経過した時点で、学習率を小さくするよう上記の機構を導入する。

4. 数値実験

本節では、物流センターでの IoT 利用[5]を想定したシミュレーションにより提案手法の性能を評価する。

4.1 評価シナリオ

提案する 3 入力 of 深層学習を用いたスループット予測の評価のため、物流センター内で多種多様な IoT アプリケーションが同一の無線チャンネルで制御されている状況 (図 1) を想定し、シミュレーションにより評価用データを取得す

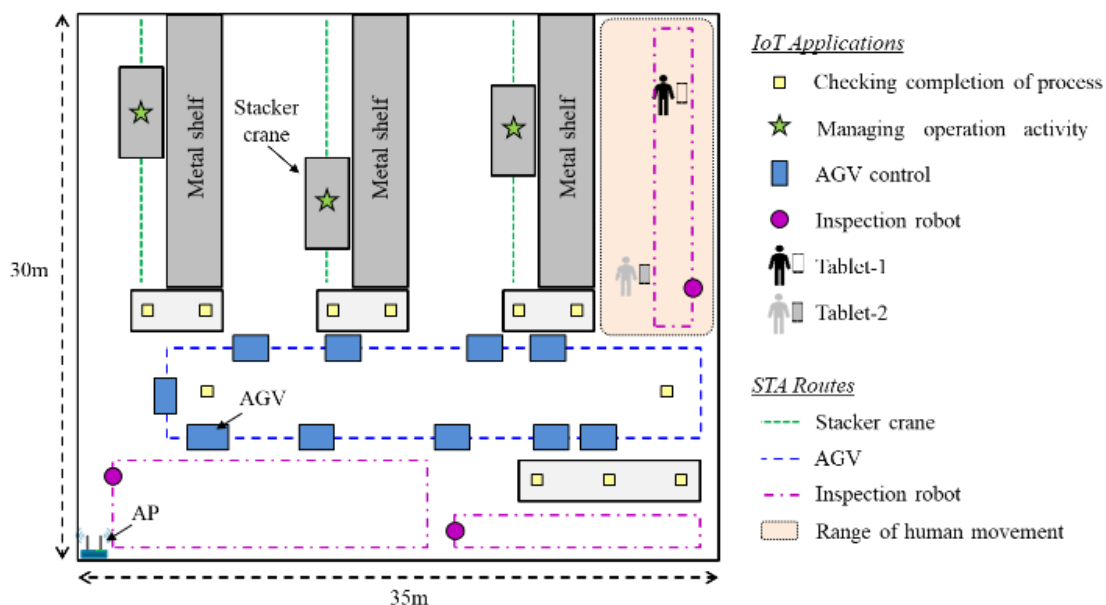


図 1 物流センターにおける IoT 利用の評価シナリオ

表 1 想定する IoT アプリケーション

Application (abbreviation)	Traffic [bps]	Velocity [m/s]	Number of STAs
Checking completion process (Check)	0.8 M	0	11
Management operation activity (Manage)	1.44 M	2	3
AGV control (AGV)	13	1	10
Inspection robot (Inspection)	6.64 M	0.01	3
Tablet-1 (Tablet-1)	0.11 M	0	1
Tablet-2 (Tablet-2)	6.64 M	1	1

る。想定する倉庫の面積は、35 m × 30 m とし、送信機からの到来波を遮る金属製の棚が 3 台設置されているものとする。表 1 に示す 6 つのアプリケーションを想定し、その内 4 つのアプリケーション (Manage, AGV, Inspection, Tablet-2) に対応する STA は移動するものとする。Manage, AGV, Inspection は図 1 に示す固定のルートを繰り返し移動する。また、Tablet-2 は人が作業確認用に持ち運ぶことを想定し、図中右上の領域をランダムに移動するものとする。

上記の評価シナリオのもと、WLAN のスループット理論式 [6] に基づくシミュレータ [7] により、IEEE 802.11g [8] に基づいてスループット、RSS、COR のシミュレーションデータを取得した。当該シミュレータでは電波伝搬を簡易なレイトレース [9] により計算し、STA の移動に伴う受信電力の変化に応じて物理層伝送レートが 0 から 54 Mbps の間で変化する。評価対象とするスループットは AP で観測する Manage に対応する STA のスループット、RSS、およびチャンネル全体での COR である。また、スループットは 10 秒毎に算出する。

4.2 予測モデル

本研究では、スループットを用いた予測よりも、RSS と COR を併せた予測のほうが高精度に予測できることを実験的に示す。3 種類の深層学習モデルを対象として、シミュレーションデータによる精度比較を行う。各モデルで、スループットのみを用いたとき (1 入力) の最適なパラメータと、スループット・RSS・COR を用いたとき (3 入力) の最適なパラメータを探索し、予測誤差が最小となるパラメータを決定する。パラメータの探索には、ベイズ最適化 [10] を用いる。探索のたびにデータの並びをシャッフルし、データの前方向から 90% を学習用、9% を検証用、残り 1% をテスト用とする。あるパラメータで学習を行い、検証データに対して最小の誤差となった重みから、テストデータでの誤差を計算する。テストデータの誤差を指標として、探索回数を 100 回に設定し最適化を進める。ただし、同一パラメータの場合でも、主に乱数の影響により学習のたびに誤差は多少上下するため、あるパラメータでの学習と誤差の計算を 2 回行い、その誤差の平均値をとることで、乱数

による影響を低減させる。決定したパラメータで構成されるモデルで学習・予測を行い、RSS・COR を併せて学習することによる予測精度の向上を検証する。学習で用いる誤差関数は MSE (Mean Squared Error) とし、バッチサイズ 128 のミニバッチ学習で 30 エポック実施する。なお、パラメータ探索の際の学習では、一定のエポックが経過した時点で誤差が低下しない場合は学習を終了する。

4.2.1 CNN の構成

CNN は、畳み込み層・バッチ正規化・活性化関数を 1 層として、入力層の後方へ複数層連結し、その出力をプーリング層・全結合層・出力層につなげた構成とする。CNN において最適化するパラメータは、層数、畳み込みフィルタ数、フィルタサイズ、入力データ長である。層数は畳み込み層・バッチ正規化・活性化関数の組の数を指す。フィルタ数とフィルタサイズは各畳み込み層で同数とする。

4.2.2 RNN・LSTM の構成

RNN と LSTM は同様の構成としており、入力層・RNN (LSTM) 層・全結合層・出力層という構成とする。RNN と LSTM で探索するパラメータは、RNN (LSTM) 層における隠れ層の数、入力データ長である。RNN (LSTM) 層を複数接続せず 1 層のみとしているが、これは複数層を重ねると誤差が増加し、精度が低下することを確認したためである。

4.3 評価結果

パラメータ最適化によって決定されたパラメータで学習および予測を行う。最適化時と同様に、データの 90% を学習用、9% を検証用、1% をテスト用とするが、テスト用データは固定の値を使用する。学習終了後、検証データに対して最小の誤差となる重みでテストデータの予測を行い、誤差を求める。この手順を複数回行い得られる予測誤差の平均値を、そのモデルでの予測誤差とする。各モデルについて学習と予測を 10 回行った。RMSE (Root Mean Squared Error) 特性とその改善率を表 2 に示す。ここで、元のスケールでの RMSE は、標準化された予測値を元のスケールに変換した値との誤差として求めている。また、改善率は (1 入力の RMSE - 3 入力の RMSE) / (1 入力の RMSE)

表 2 各予測モデルにおける 1 入力・3 入力時の RMSE 特性の比較および改善率

	標準化データ			元データ [bps]			改善率
	1 入力	3 入力	差	1 入力	3 入力	差	
CNN	0.4445	0.4428	0.0017	50955	50755	200	0.0039
RNN	0.4273	0.4114	0.0159	48979	47157	1821	0.0372
LSTM	0.4163	0.4090	0.0073	47721	46885	836	0.0175




図 2 真値と予測値の比較

で定義される改善された割合を表す。さらに、図 2 に各サンプルの真値と LSTM による入力数別の予測値との比較と、図 3 にその一部を拡大した図を示す。

表 2 を見ると、どのモデルも複数情報を利用することで、1 入力と比較して予測誤差が減少したことが確認できる。元データとの差は、CNN では 200 [bps] となり、精度向上は微小である。一方 LSTM では差が 836 [bps] であり、1 入力から 1.75% 減少した。さらに、RNN においては 1821 [bps] の差が現れ、1 入力の予測誤差と比較して 3.72% 減少し、対象とした深層学習モデルの中では、予測精度が最も大きく向上した。RNN や LSTM といった再帰的な構造を持ったネットワークは過去の情報を利用することができるため、複数のデータ間での時間的な特徴を捉えることができ、精度向上につながったと考えられる。図 3 では、多くの点で 1 入力と 3 入力ではほとんど同様の値を予測しているが、一部で 3 入力のモデルの方が 1 入力のモデルに対し、真値に近い値を予測している。213 サンプル目のような、スループットが急激に変化するような値をとるときに、1 入力に比べて 3 入力ではその変化に近い値を予測することができている。複数入力を採用することでこのような急激な変化に対応できるため、予測精度が向上したと考えられる。

また、LSTM と RNN で比較すると、RNN の減少率が LSTM の 2 倍程度となっている。LSTM はゲートやメモリーセルといった仕組みがあり、RNN と比べると、スループットのみでも、より効果的にデータの特徴を捉えることができる。LSTM は 1 入力のモデルにおいても比較的高い精度で予測ができており、RNN のモデルほどの変化が生まれなかったため、LSTM の減少率が小さくなったと考えられる。一方、CNN について結果を見ると、予測値の誤差は大きくなっている。このことから CNN は RNN や LSTM と比較すると、時系列データに適していないといえる。しかし、入力情報を増やしたことによって、精度は僅かであるが向上している。以上より、RSS と COR をスループットと併せて学習・予測することで予測モデルの構造によらず精度の向上を確認した。

5. むすび

本論文では、スループットに加え、RSS と COR を用いたスループット予測を提案した。物流センターにおける IoT 利用を想定した評価シナリオのもと、WLAN のスループットシミュレータにより取得した評価データに対し、深層学習モデルを用いて予測誤差を比較し、提案手法によって予

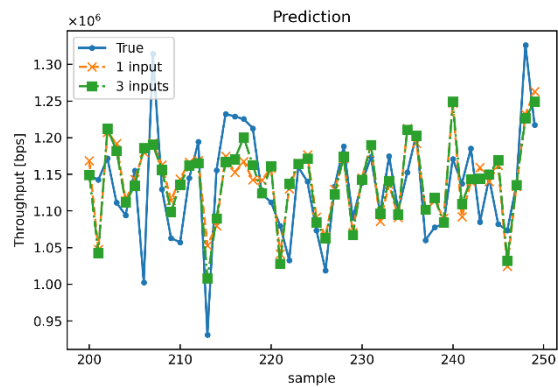


図 3 拡大した真値と予測値の比較

測精度が最大で 3.7% 程度向上することを示した。さらに、それぞれ別の構造を持った複数の深層学習モデルで予測結果を比較することで、モデルの構造によらず、スループットの予測に RSS と COR を用いて精度が向上することを確認した。

謝辞

本研究は、総務省の「電波資源拡大のための研究開発 (JPJ000254)」における委託研究「狭空間における周波数稠密利用のための周波数有効利用技術の研究開発」により実施した成果を含む。

参考文献

- [1] M. Wollschlaeger, et al., "The Future of Industrial Communication: Automation Networks in the Era of the Internet of Things and Industry 4.0," IEEE Ind. Electron. Mag., Vol.11, No.1, (2017).
- [2] Y. Hou, K. Yano, N. Suga, J. Webber, E. Nii, T. Higashimori, S. Denno, Y. Suzuki, "A Study of Throughput Prediction using Convolutional Neural Network over Factory Environment," IEEE 23rd International Conference on Advanced Communications Technology (ICACT), (2021).
- [3] A. Krizhevsky, I. Sutskever, G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS), Vol.1, (2012).
- [4] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network," Physica D: Nonlinear Phenomena, (2020).
- [5] "IEEE 802 Nendica Report: Flexible Factory IoT—Use Cases and Communication Requirements for Wired and Wireless Bridged Networks," (2020).
- [6] T. Iwami, I. Roslan, Y. Takaki, K. Yamori, C. Ohta, H. Tamaki, "Utility-Based Distributed Association Control Scheme with User Guidance for IEEE802.11 Wireless LANs," IEICE Transactions on Communications, Vol.E98-B, No.8, (2015).
- [7] N. Suga, K. Yano, J. Webber, Y. Hou, T. Higashimori, Y. Suzuki, "Prediction of QoS Outage Probability for Wireless Communication in Factory Environments," in Proc. IEEE International Conference on Internet of Things, Embedded Systems and Communications (IINTEC), (2019).
- [8] "Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications," IEEE P802.11-2016, (2016).
- [9] J. Webber, N. Suga, A. Mehbodniya, K. Yano, and T. Kumagai, "Study on Fading Prediction for Automated Guided Vehicle Using Probabilistic Neural Network," in Proc. 2018 Asia-Pacific Microwave Conference (APMC), (2018).
- [10] M. Pelikan, D. E. Goldberg, E. Cant' u-Paz, "BOA: the Bayesian optimization algorithm," Proceedings of the Genetic and Evolutionary Computation Conference, Vol.1, (1999).