

画像化手法による超多接続の通信環境推定と GAN による AI 学習データ生成・拡張法

代表研究者	安 昌 俊	千葉大学大学院工学研究院	教授
共同研究者	鄭 淵 湖	韓国国立釜慶大学	工学部 教授

1 はじめに

第5世代(5G)移动通信システムの商業化は2020年にスタートしたが、早くも世界各国では6Gの実現に向けた必要な通信技術についての議論を始めている。6Gでは100Gbps以上の超高速、99.99999%の高信頼、1000万デバイス/km²の超多接続などが要求条件とされる。6Gではテラヘルツ波など、5Gのミリ波よりも一層高い周波数帯が使われるため電波の直進性が増す。さらに減衰が大きく伝搬距離も短くなるため、見通し通信ができる状況を増やしていくことが必要となる。ロスの少ない多くの通信路を確保して通信を行うためには、大規模MIMOシステムを狭いエリアで複数分散配置する必要がある。このような分散型大規模MIMOシステムでは、多くのユーザや無線端末が狭いエリアに集中するため、周囲の環境の変化等による干渉の時変動が激しく、遮蔽による通信品質の劣化も生じる。そのため、超多接続環境下での高速・低遅延でその予測と推定・補償がシステム実現上の重要な課題となる。研究代表者は、人工知能が得意とする画像データ処理に着目し、受信信号を人工知能が学習しやすい画像化(スペクトログラム)することで、チャネルパラメータの高速推定に成功した。スペクトログラムとは、複合信号を窓関数に通して3次元のグラフ(時間、周波数、信号成分の強さ)で表した結果を現したものである。本研究の目的は、「人工知能や機械学習による通信環境推定は、6G無線環境下でも有効か」であり、6G無線環境下の大規模MIMOシステムなどに応用可能な新しい画像化手法とそれを用いた低演算・低遅延での通信環境推定手法の提案とその有効性を明確にすることである。さらに、無線通信に人工知能の機械学習を応用する上で最も重要な作業は、AI学習用のデータセットを収集することである。機械学習を用いて優れた性能を発揮させるためには、膨大な学習データが必要となる。しかし、実世界の通信環境は多様であり、大量のデータセットを集めることは非常に困難である。従って、小さなデータセットから無線信号データセットを拡張できる敵対的生成ネットワーク(GAN: generative adversarial network)を用いた新しいデータセット生成・拡張法の提案と評価、さらにGANによるデータ拡張には十分なデータが必要であり、転移学習(TL: transfer learning)と同様に、トレーニングデータが不十分な場合は機能しなくなる可能性がある。また、GANでは2つのネットワークをトレーニングするためかなりの計算が必要であり、その結果、無線通信における機械学習(ML; machine learning)のデータ拡張は、データ収集と計算リソースの両方の点で依然として課題となっている。本研究では、人工知能を用いた通信環境推定とそれに必要な膨大な学習データを効率よく生成し、性能を改善できる方法について、検討してその結果を明確にすることである。

2 提案システム

本研究では、無線通信環境を推定するためのマルチモーダル学習ベースのネットワークを提案する。提案ネットワークでは、畳み込みニューラルネットワーク(CNN: convolutional neural network)の出力を分類として使用し、MLを用いた通信路推定(SNRおよびKファクター)には回帰がよく利用されるが、実際のパラメータ制御では推定値がどの範囲に該当するかがわかれば十分であり、分類の離散値でも十分実用的である。さらに、分類は回帰よりも軽量なネットワークを実現できるため、トレーニングデータセットが限られている本研究のような状況では分類の方が適している。提案されたネットワークは、受信信号のシーケンスデータと短時間フーリエ変換(STFT: short-term Fourier transform)によって得られたスペクトログラム画像を同時にネットワークに入力し、同じ信号から数値および画像形式へのこの変換により、モダリティの数を増やすことができるため、効率が最大化され、少量の無線信号データから推定に必要な特徴が抽出される。各モダリティは特徴抽出の堅牢性が異なるため、「特徴の多様性」を得ることができる。複数の異なる特徴抽出ネットワークを並列に実装して組み合わせることで、特徴抽出の高効率とネットワークの計算複雑性の低さの両方を実現できる。

2-1 画像化（スペクトログラム）データ

図1は様々なチャネルで取得された OFDM 信号(SNR 20dB)のスペクトログラム画像を示す。スペクトログラムは、時間領域と周波数領域で受信信号の電力密度を表す単純な画像データである。したがって、チャネル推定を行うために挿入する参照信号がなくても簡単にチャネルの変動を確認できる。図1に示された結果により、様々なチャネルでもスペクトログラム画像によりチャネルの特徴を抽出し、適切に分類を行うことができる。




図1 様々なチャネルで取得された OFDM 信号(SNR 20dB)のスペクトログラム画像

2-2 CNN と GAN を用いた学習データ生成法

無線通信に人工知能の機械学習を応用する上で最も重要な作業は、AI 学習用のデータセットを収集することである。機械学習を用いて優れた性能を発揮させるためには、膨大な学習データが必要となる。しかし、実世界の通信環境は多様であり、大量のデータセットを集めることは非常に困難である。従って、小さなデータセットから無線信号データセットを拡張できる GAN を用いた新しいデータセット生成・拡張法の有効性を明確にさせる。図2に CNN と GAN

を用いた学習データ生成法の概要を示す。ここでは通信環境を決定づける主要な要因である SNR の間隔推定を対象とする。推定には CNN を用い、入力には受信信号を短区間フーリエ変換したスペクトログラム画像を使用する。このスペクトログラム画像を GAN に学習させることで疑似画像を生成させデータセットを拡張する。GAN とは生成器(generator)と識別器(discriminator)のニューラルネットワークより構成されるネットワークである。生成器はノイズより疑似データを作成し識別器は教師データか生成器が生成する疑似データを判断する。生成器は識別器を騙すようなデータを生成するように、識別器は生成器に騙されないように敵対的な関係を持たせ、学習を進めていくため飛躍的な性能の向上が期待できる。この特性を活用し、様々な無線通信環境下で得られたデータを同時に GAN に学習させることで、生成器においてドップラーシフトによらない本質的な SNR の特性を模した疑似データを生成することが可能となる。ここで生成したデータを SNR 推定における学習データとして用いることで、データ不足による過学習を抑制し、さらにドップラーシフトに対してロバスト性を向上させる効果を同時に達成することができる。




図2 GAN を用いた AI 学習用の無線信号データセット生成・拡張

2-3 マルチモーダル学習とチャネル推定

これまでの検討では、GAN によるデータ拡張にも十分なデータが必要であり、転移学習と同様に、トレーニング データが不十分な場合は機能しなくなる可能性があった。また、GAN では 2 つのネットワークをトレーニングするためかなりの計算が必要であり、その結果、無線通信における 機械学習のデータ拡張は、データ収集と計算リソースの両方の点で依然として課題となっている。本研究では、人工知能を用いた通信環境推定とそれに必要な膨大な学習データを効率よく生成し、性能を改善できる方法として、マルチモーダル学習とチャネル推定法を提案する。




図 3 提案マルチモーダルネットワーク構造

図 3 は、提案マルチモーダルネットワーク構造を示す。提案方式では、2 つの異なる CNN を使用して、それぞれシーケンス データとスペクトログラムから特徴を抽出し、最終的にそれらを組み合わせて通信環境パラメータを同時に推定する。そのため、最適なネットワーク構造を選択する必要があるが、ここでは早期融合、中期融合、後期融合の 3 つのパターンを検討する。早期融合では、シーケンス データと画像データがそれぞれ 1 回トレーニングブロックを通過し、2 つのトレーニングブロック後に融合および推定を行う。中期融合では、2 つのモダリティが 2 つのトレーニングブロックを通過し、特徴の融合が実行され、1 つのトレーニングブロック後に推定が実行される。後期融合では、2 つのモダリティがそれぞれ 3 つのトレーニングブロックを経由し、完全に接続された層によって結合され、推定を行う。一般に、CNN は入力として実数ベクトルを必要とする。そのため、受信信号シーケンスという複雑なデータを直接入力することはできない。本研究でのシーケンスデータは、トレーニングのために受信信号の実部と虚部に分割され、トレーニングプロセスを行う。図 3 により、シーケンスデータは負の値を取ることができるが、色情報を持たない。一方、スペクトログラムは負の値を取らず変換誤差が生じるが、SNR や K ファクターに関連したパワー歪みが特徴として明確に現れるため、CNN に適している。提案ネットワークは、異なる特徴を持つモダリティを同時に組み合わせることで、限られたトレーニングデータでも互いに補完するようにトレーニングすることができる。その結果、軽量の CNN で限られたトレーニングデータからも特徴を抽出することが可能となり、安定した推定を実現できる。

3 計算機シミュレーション結果

このセクションでは、提案されたマルチモーダルネットワークの推定精度をさまざまなベンチマークスキームと比較して評価を行う。表 1 に示すパラメータを使用して無線信号データを生成する。ネットワークのオフライン トレーニングフェーズでは、トレーニング データセットの 80% を実際のトレーニングに、20% を検証に割り当てる。Adam 最適化アルゴリズムを使用し[1]、50 エポ

表 1 シミュレーション諸元

Parameter	Value
IFFT size	64
Number of pilot symbols	2
Number of subcarriers	50
Number of information symbols	32
Length of guard interval	16
Modulation	64QAM
Bandwidth	20 MHz
Doppler shift	1 Hz
Number of paths	15
Fading	Rayleigh / Rician fading

ックにわたってトレーニングを実行し、初期学習率を 0.0001 に設定する。この検討では、SNR または K ファクターの間隔に基づいて分類することにより、SNR または K ファクターを推定する。たとえば、3 dB 間隔の SNR 値を 0 dB から {0、3、6、9、12} dB として 5 つのクラスに分類する。また、K ファクターの推定も同様に行われ、用意した K ファクターを 0 から始まる K ファクター間隔に従って分類を行う。




図 4 様々なマルチモーダルネットワーク構造における SNR 推定の精度

図 4 には、SNR 推定の結果を示す。3 つのアーキテクチャの中で、中期融合アーキテクチャの推定精度が最も高いことがわかる。中期融合アーキテクチャは、シーケンスとスペクトログラムデータから効果的に特徴を抽出し、融合後に再トレーニングによって校正し、各トレーニングデータセットに対して最高の SNR 推定精度を実現する。対照的に、後期融合アーキテクチャでは、提案されたマルチモーダル学習の潜在能力が十分に活用されておらず、融合後にトレーニングブロックを通じて再トレーニングされないため、シーケンスとスペクトログラムデータは十分に校正されていない。早期融合アーキテクチャでは、各モダリティからのトレーニングがさらに必要になり、特徴ベクトルの冗長性が生じる。




図 5 様々なマルチモーダルネットワーク構造における K ファクター推定の精度

図 5 には、K ファクターの推定結果を示す。SNR 推定とは異なり、図 5(左)に示す 300 データセットでトレーニングした場合、ネットワークの構造に関係なく推定精度が大幅に変化しないことがわかる。また、図 5(右)に 500 データセットでトレーニングしたネットワークを使用した推定を見ると、中期融合アーキテクチャの結果は、トレーニング データセットが 2 倍になっても大幅に変化を見られないが、K ファクター間隔が 5 の場合、後期融合は中期融合に 2.49% 近づく。一方、早期融合では、トレーニングデータセットが増やすにつれて推定精度も向上する。これらの結果は、理想的なアーキテクチャが推定対象によって異なることを

示す。SNR 推定の場合、より高い精度を達成するには、より早い段階で融合する必要があり、K ファクター推定では、より後の段階で融合するほど精度が向上できる。




図 6 SNR 推定の精度

図 6 (左) は、さまざまな方式と比較した SNR 推定精度を示す。結果から提案されたマルチモーダル推定は、すべての方式の中で最高の精度を達成していることがわかる。ML ベースではない方式である M_2M_4 [2] は、ノイズの影響を受けやすいため、他のどの ML ベース方式よりも SNR 推定精度が低くなっている。ML による特徴抽出の観点から、シーケンスデータとスペクトログラム画像を入力として使用する方式を比較すると、シーケンス データは、SNR 間隔が狭い領域でより良い推定精度を実現できる。対照的に、スペクトログラム画像は、SNR 間隔が広い領域でより良いパフォーマンスを示す。これは、特徴抽出の強さがモダリティによって異なることを示す。提案されたマルチモーダル学習ネットワークは、シーケンスデータとスペクトログラムに基づいているため、特徴の多様性を高め、1 つのモダリティから抽出された特徴がモデルを効果的に捉えていない場合でも、他のモダリティを補う。この推定方式は、トレーニングデータが限られていることと、レイリーフェーディングによって予測できない電力変動が原因で特徴抽出が困難な場合に効果的であることが示された。特徴の多様性を高めることで、安定した推定性能を得ることができ、精度が最大化可能であることを示した。

4 まとめ

本研究では、マルチモーダルネットワークを使用した通信環境推定法を提案した。提案方式では、受信信号がシーケンスデータとスペクトログラム画像の 2 つのモダリティに変換され、2 つの形式のシーケンスデータとスペクトログラムを入力として受け取り、各入力からそれぞれ特徴を抽出し、最終的にそれらを組み合わせることで、推定性能向上することができ示した。

【参考文献】

- [1] M. Wang, S. Lu, D. Zhu, J. Lin, and Z. Wang, "A high-speed and low-complexity architecture for softmax function in deep learning," in Proc. IEEE Asia Pacific Conf. Circuits Syst. (APCCAS), pp. 223–226, October 2018.
- [2] D. R. Pauluzzi and N. C. Beaulieu, "A comparison of SNR estimation techniques for the AWGN channel," IEEE Trans. Commun., vol. 48, pp. 1681–1691, Oct. 2000.

- [3] S. Kojima, K. Maruta, Y. Feng, C.-J. Ahn, and V. Tarokh, "CNN-Based Joint SNR and Doppler shift classification using spectrogram images for adaptive modulation and coding," IEEE Trans. Commun., vol. 69, no. 8, pp. 5152–5167, Aug. 2021.
- [4] X. Xie, S. Peng, and X. Yang, "Deep learning-based signal-to-noise ratio estimation using constellation diagrams," Mobile Inf. Syst., vol. 69, no. 2020, pp. 1–9, 2020.
- [5] T. Ngo, B. Kelley, and P. Rad, "Deep learning based prediction of signal-to-noise ratio (SNR) for LTE and 5G systems," in Proc. IEEE 8th Int. Conf. Wireless Networks Mobile. Commun. (WINCOM), pp. 1–6, Oct. 2020.
- [6] Z. Tang, M. Tao, J. Su, Y. Gong, Y. Fan, and T. Li, "Data augmentation for signal modulation classification using generative adverse network," in Proc. IEEE 4th. Int. Conf. Electronic Info. Commun. Technology (ICEICT), pp. 450–453, Aug. 2021.

〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
Joint SNR and Rician K-Factor Estimation Using Multimodal Network over Mobile Fading Channels	IEEE Transactions on Machine Learning in Communications and Networking	2024 年 6 月
Analysis of Outage Probability for Massive MIMO Systems under Multi-Cell and Imperfect CSI Environments	IEICE Communications Express	2024 年 2 月
Timing Synchronization Based on Supervised Learning of Spectrogram for OFDM Systems	IEEE Transactions on Cognitive Communications and Networking	2023 年 10 月
Regression CNN based Fast Fading Channel Tracking using Decision feedback channel estimation	Journal of Signal Processing	2023 年 5 月
Accurate and Doppler Robust SNR Estimation using Multimodal CNN	IEEE VTC2024 spring	2024 年 6 月
Vehicle-To-Vehicle Communication Channel Estimator Based on Gate Recurrent Unit	IEEE International Conference on Electronics, Information, and Communication (ICEIC2024)	2024 年 1 月
Efficient Joint Estimation Methods of Channel and IQ Imbalance for MIMO-OFDM Systems	IEEE International Conference on Electronics, Information, and Communication (ICEIC2024)	2024 年 1 月
Spectrally Efficient Frequency Division Multiplexing with QRM-MLD for Rician Fading Channel	IEEE International Conference on Advanced Technologies for Communications (ATC2023)	2023 年 10 月
Adaptive Modulation and Coding for Uplink Massive MIMO with Semi-Blind Interference Suppression Under Multicell Environment	IEEE International Conference on Advanced Technologies for Communications (ATC2023)	2023 年 10 月
Low-Computation DOA Estimation Using Virtual Antenna in 2D MIMO Systems	IEEE International Conference on Advanced Technologies for Communications (ATC2023)	2023 年 10 月
Each Layer Adaptation for Throughput Enhancement of LACO-OFDM	IEEE International Conference on Advanced Technologies for Communications (ATC2023)	2023 年 10 月