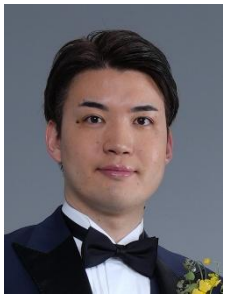
周波数利用効率向上のための深層学習による複数の通信環境同時推定手法の開発

Development of Deep Learning-Based Joint Estimation of Multiple Communication Environment Parameters for Improved Spectral Efficiency



小島　駿（Shun Kojima, Ph. D.）
千葉大学　大学院工学研究院　准教授
(Associate Professor, Graduate School of Engineering, Chiba University)
電子情報通信学会　IEEE　他
受賞：コニカミノルタ画像科学奨励賞 (2026 年)，高柳健次郎財団研究奨励賞 (2023 年)，電子情報通信学会学術奨励賞 (2023 年)，無線通信システム研究会活動奨励賞(2021 年) 他
研究専門分野：無線通信工学　情報学　機械学習

あらまし

限られた周波数資源を有効に利用するには、信号を高密度に配置する伝送方式と、通信環境に応じた適応制御の両立が重要である。本研究では、受信信号の特徴を深層学習で読み取り、制御に必要な複数の通信環境情報を推定する手法を検討した。まず、サブキャリア間隔を圧縮するスペクトル有効周波数分割多重（SEFDM）を対象に、スペクトログラムと畳み込みニューラルネットワークを用いた信号対雑音電力比（SNR）の分類手法を構築した。圧縮率 0.5、SNR の分類間隔 2 dB の 4 クラス分類では、雑音のみの通信路で約 92%、レイリーフェージング通信路で約 80%の精度を得た。さらに、複数の信号表現を統合するマルチモーダル構成へ展開し、移動通信路における SNR と K ファクタの同時推定などを検討した。これらの成果を通じて、受信信号から有用な特徴を直接抽出し、高効率な適応制御につなげる通信環境推定の基盤を示した。

１．研究の目的

無線通信は、人と人との情報交換に加え、センサ、車両、産業機器などの接続を支える基盤となっている。接続端末数や通信データ量が増加する中で、限られた周波数帯域から、いかに多くの情報を安定して伝送するかが重要な課題である。新たな周波数帯域の開拓だけでなく、既存の帯域をより有効に活用する仕組みが求められる。

通信環境に合わせて変調方式や符号化率を切り替える適応変調符号化（AMC）*1 は、この課題に対する有効な手段である[1]。ただし、適切な制御には、現在の受信状態を正しく把握しなければならない。本研究でいう「複数の通信環境情報」とは、異なる場所の情報ではなく、信号対雑音電力比（SNR）*2、移動に伴うドップラーシフト、伝搬状態を表す K ファクタ、同期タイミングのずれなど、受信信号に重なって現れる複数の物理的な要因である。

本研究の目的は、これらの情報を受信信号から深層学習によって抽出し、周波数利用効率と通信品質を両立する適応制御の基盤を構築することである。特に、周波数方向に信号を圧縮する SEFDM に着目し、自己干渉が存在しても利用できる推定法を検討した。併せて、複数の信号表現を組み合わせることで、単一の入力形式では捉えにくい特徴を補い、複数の通信環境情報を同時に扱う推定手法への展開を図った。

２．研究の背景と関連する研究動向

広く用いられている直交周波数分割多重（OFDM）*3 は、互いに干渉しないように配置した多数のサブキャリアで情報を伝送する。これに対して、スペクトル有効周波数分割多重（SEFDM）*4 は、サブキャリア間隔を狭めることにより周波数利用効率を高める方式である。圧縮率 α が 1 の場合は OFDM に相当し、α を小さくするほど信号を周波数方向に密に配置できる。一方で、信号同士の直交性が崩れるため、サブキャリア間に自己干渉が生じる。このため SEFDM では、非直交信号の検出手法[2]や自己干渉を除去する技術の実験的検証[3]が進められてきた。周波数利用効率を高めるには、信号を復元する処理だけでなく、干渉を含んだ受信信号から適応制御に必要な情報を取り出す処理も重要である。

通信環境推定では、既知の参照信号を利用する方法が基本となる。しかし、参照信号の増加はデータ伝送

周波数利用効率向上のための深層学習による複数の通信環境同時推定手法の開発

Development of Deep Learning-Based Joint Estimation of Multiple Communication Environment Parameters for Improved Spectral Efficiency

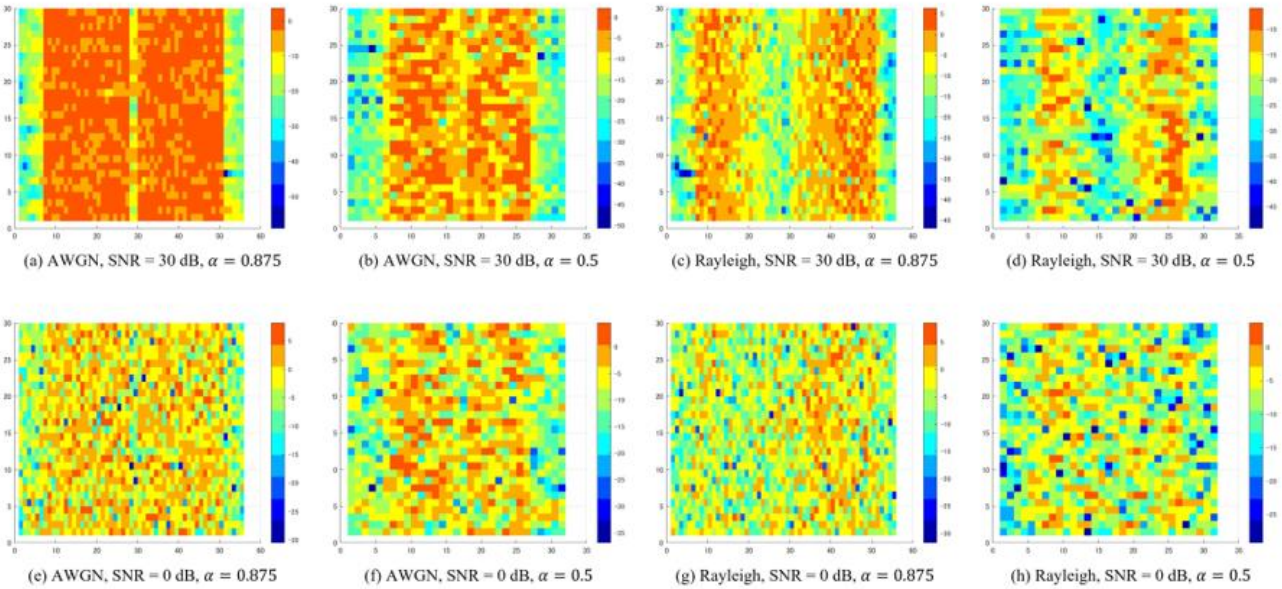


図 1　SEFDM 受信信号のスペクトログラムの例。上段は SNR＝30 dB、下段は 0 dB である。左から、AWGN（α＝0.875、0.5）、レイリーフェージング（α＝0.875、0.5）の順に示す。横方向は周波数、縦方向は時間に対応し、色は電力を表す。各パネルのカラースケールは異なる。

に利用できる資源を減らし、複雑な前処理は制御情報の取得を遅らせる要因となる。特に、端末が移動する場合には、推定値が得られた時点で通信環境が変化している可能性もある。推定精度に加え、観測量と処理時間の両面から効率を考える必要がある。

国内外の関連研究では、深層学習による通信路特徴の抽出と適応変調符号化への応用[4]や、CNN と LSTM を組み合わせたドップラーシフトの推定[5]などが報告されている。本研究は、こうした深層学習による特徴抽出・推定の考え方を基盤として、SEFDM の自己干渉下での SNR 推定と、複数の信号表現を統合した通信環境推定に取り組んだものである。

３．研究の方法

３．１　受信信号を「特徴が見える形」に変換する

受信波形には、雑音、反射波、移動、同期のずれなどの影響が重なっている。同じ信号でも、時間波形、周波数スペクトル、振幅と位相の分布では、見えやすい特徴が異なる。そこで、受信 IQ データ*5、スペクトログラム、周波数ごとの電力分布を表す電力スペクトル密度画像、振幅と位相の分布を示すコンスタレーションなどを入力候補とし、推定対象に適した表現を検討した。

SEFDM の SNR 推定では、信号を短い時間区間に分けて周波数成分を求め、電力の分布を画像として表すスペクトログラム*6 を用いた。図 1 に示すように、雑音の強さやフェージング、圧縮率によって、画像中の電力分布や模様が変化する。この違いを学習させることで、自己干渉をあらかじめ除去せずに、SNR に関係する特徴を抽出する。

３．２　畳み込みニューラルネットワークによる分類

特徴抽出には、画像の局所的な模様を捉える畳み込みニューラルネットワーク（CNN）*7 を用いた[6]。通信路条件を変えて生成した受信信号からスペクトログラムを作成し、設定した SNR と対応づけて学習する。運用時には、学習済みのネットワークに未知の受信画像を入力し、対応する SNR のクラスを出力する。数値評価では、各 SNR クラスについて生成した 1000 枚のスペクトログラム画像のうち、ランダムに選んだ 90%を学習に、残りの 10%をテストに用いた。入力する画像の大きさを一定とし、受信信号の条件による分類性能の変化を比較した。

周波数利用効率向上のための深層学習による複数の通信環境同時推定手法の開発

Development of Deep Learning-Based Joint Estimation of Multiple Communication Environment Parameters for Improved Spectral Efficiency

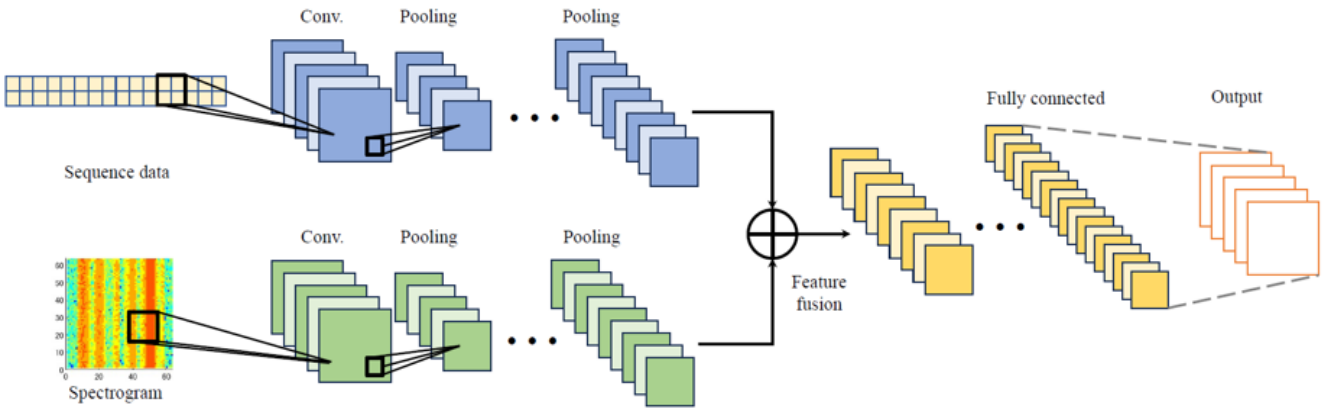


図 2　マルチモーダル CNN の構成例。上段の時系列データと下段のスペクトログラムから別々に特徴を抽出し、後段で統合して通信環境情報を推定する。Conv.は畳み込み、Pooling は特徴を集約する処理、Feature fusion は特徴統合、Fully connected は全結合層を表す。

ここで扱う推定は、SNR を連続値として求める回帰ではなく、あらかじめ設定した候補から選ぶ分類である。したがって、分類精度だけでなく、候補間の間隔とクラス数を併せて評価する必要がある。また、参照信号やチャネル等化を必要としないという特徴は、この分類器の入力処理に関するものであり、通信システム全体の同期やデータ復調まで不要にするものではない。

３．３　複数の表現を統合するマルチモーダル構成

複数の通信環境情報を扱うため、異なる入力表現を組み合わせるマルチモーダル CNN*8 も検討した[7]。図 2 の構成では、時系列データとスペクトログラムを別々の畳み込み層で処理し、得られた特徴を後段で統合する。同じ信号を異なる観点から読み取ることにより、一方の表現だけでは捉えにくい情報を補完する考え方である。

評価では、推定精度に加えて、学習データ量、低 SNR 条件、学習時と異なる通信路条件の影響を検討した。また、ソフトウェア無線機による実測データの取得と評価を進め、シミュレーションと実環境の違いを調べた。推定結果を変調方式、符号化率、SEFDM 圧縮率の選択につなげることも検討し、分類精度を最終的な通信性能に結び付ける視点を重視した。

４．研究成果とその意義

４．１　SEFDM の自己干渉下における SNR 分類

図 3、4 に、SEFDM の圧縮率を変化させた場合の SNR 分類精度を示す。評価対象は、加法性白色ガウス雑音（AWGN）のみを加えた通信路と、複数の伝搬経路によるレイリーフェージング*9 を伴う通信路である。変調方式 QPSK とし、周波数成分を求める高速フーリエ変換（FFT）の基本サイズは 64 とした。レイリーフェージングの例では、3 パスの指数減衰型遅延プロファイルと、最大ドップラー周波数 0.001 Hz を設定した。

図 3、4 から、圧縮率を小さくすると自己干渉が強くなり、分類精度は低下する傾向を示した。それでも、圧縮率 0.5、SNR の分類間隔 2 dB の 4 クラス分類では、AWGN 通信路で約 92%、レイリーフェージング通信路で約 80%の精度が得られた。干渉を含む受信信号でも、スペクトログラムに残る SNR の特徴を CNN が捉えられることを示す結果である。さらに、圧縮率 0.875、FFT サイズ 64 とし、0～20 dB を 2 dB 間隔の 11 クラスに分けた評価では、AWGN 通信路で全体として約 92%の分類精度を得た。一方、フェージングのある場合には電力分布の変動が加わり、分類が難しくなることも確認した。これらの値はそれぞれの評価条件での分類結果であり、任意の通信路に対する推定誤差や、高速移動環境での性能を一律に保証するものではない。

FFT サイズを変えた評価では、サイズを大きくすることで分類精度が向上する傾向も確認した。観測されるサブキャリア数が増えることにより、画像から抽出で

周波数利用効率向上のための深層学習による複数の通信環境同時推定手法の開発

Development of Deep Learning-Based Joint Estimation of Multiple Communication Environment Parameters for Improved Spectral Efficiency

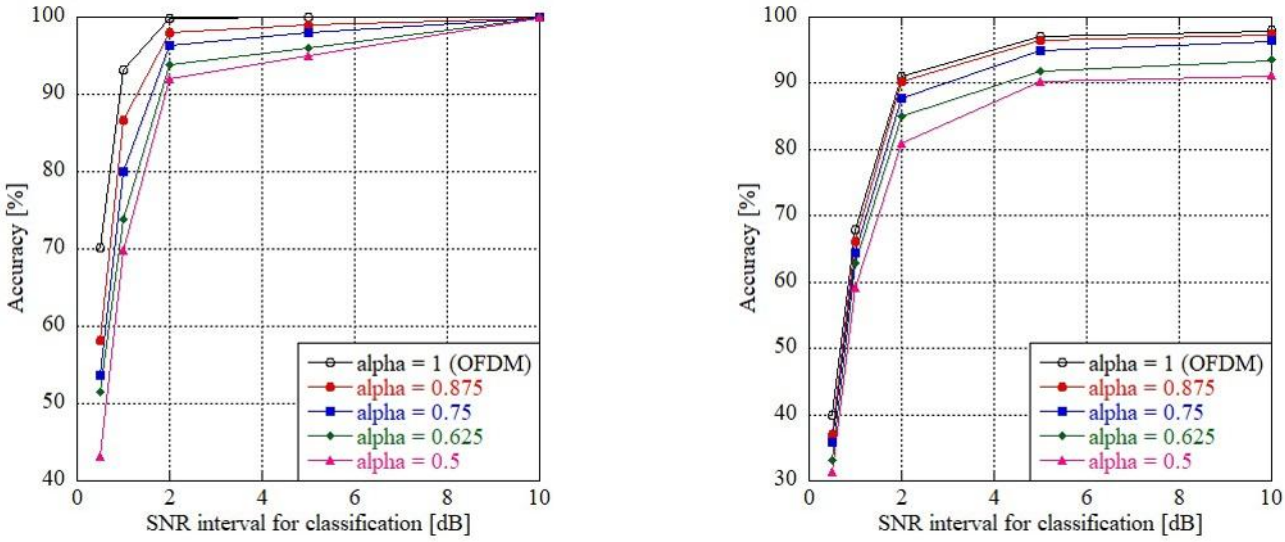


図 3　圧縮率を変化させた場合の AWGN（左）、レイリーフェージング（右）環境下の SNR 分類精度（4 クラス分類）。横軸は分類する SNR の間隔、縦軸は分類精度を示す。α＝1 は OFDM に相当する。圧縮率 0.5、分類間隔 2 dB では、AWGN で約 92%、レイリーフェージングで約 80%の精度が得られた。

きる特徴が増えたためと考えられる。この結果は、深層学習モデルの設計に加えて、信号の観測範囲や入力画像の構成も推定性能に関係することを示している。

４．２　複数の通信環境情報を推定するための基盤

移動フェージング通信路を対象とした検討では、SNR とライスフェージングの K ファクタ*10 を同時に推定するマルチモーダル構成を用いた[7]。単一の入力表現を用いる構成に対して、特に学習データが限られる場合や低 SNR 条件での推定精度の劣化を抑えられることを示した。これは、ネットワークを複雑にするだけでなく、学習させる信号表現の選択と組合せが重要であることを示している。

また、通信環境を把握するための関連する基盤技術として、OFDM のスペクトログラムを用いた同期タイミング推定も検討した[8]。SNR とドップラーシフトの同時分類に関する先行研究[4]と併せると、複数の物理量を受信信号の特徴から捉える方向性が明確になる。これらの知見は、推定対象や通信方式に応じた個別の検証に基づくものであり、SEFDM を含む統合的な通信環境推定へ発展させる基盤となる。

４．３　実測環境と適応制御への展開

ソフトウェア無線機を用いた基礎的な実機評価では、実測信号への適用可能性を確認する一方、シミュレーションとのデータ分布の違いや測定系の非理想性が性能に影響することを整理した。実測データによる再学習や、入力表現の選択を含めて評価する重要性が明らかになった。

適応制御への展開では、OFDM と SEFDM の切替えに加え、変調方式、符号化率、圧縮率を選択する枠組みを検討した。重要なのは、分類精度を高めること自体ではなく、推定誤りが伝送誤り率やスループットに及ぼす影響を踏まえて制御することである。本研究の意義は、信号を高密度に配置する伝送技術と、受信信号から状態を読み取る学習技術を結び付けた点にある。

５．将来展望

短期的には、屋内外の多様な伝搬環境や移動端末、外部干渉源を含む実測データを拡充し、学習時と異なる条件での汎化性能を検証することが課題である。特に、SEFDM の自己干渉、移動による時間変動、外部からの干渉が同時に存在する場合を扱い、推定結果が信頼できる範囲を明らかにする必要がある。中期的には、並列演算向けの GPU や回路を書き換えられる FPGA などへの実装を進め、受信データの取得、信号表現への変換、推論、制御までを含む処理時間を評価する。ネットワーク単体の推論速度だけでは、通信制

周波数利用効率向上のための深層学習による複数の通信環境同時推定手法の開発

Development of Deep Learning-Based Joint Estimation of Multiple Communication Environment Parameters for Improved Spectral Efficiency

御のリアルタイム性を判断できないためである。推定精度、処理遅延、参照信号の負担を含めて、実効的な周波数利用効率を検証することが重要となる。
将来的には、限られた周波数帯域を共有する無線ネットワークや、移動体を含む IoT、電波環境マップの生成、無線 AI 制御への応用が期待される。同じ受信信号を複数の表現に変換して特徴を統合する設計は、SEFDM に限らず、複数の物理要因が重なる環境での信号処理にも展開できると考えられる。

おわりに

本研究では、スペクトログラムと深層学習による SEFDM の SNR 分類、およびマルチモーダル構成による複数の通信環境情報の推定を検討した。自己干渉を含む受信信号から有用な特徴を抽出できること、入力表現の組合せが推定性能を左右することを示した。今後は実環境での検証と適応制御との統合を進め、周波数資源を効率よく利用する無線通信基盤につなげていく。

用語解説

*1 適応変調符号化（AMC）：通信環境に応じて、変調方式と誤り訂正符号の符号化率を切り替える制御方式。

*2 信号対雑音電力比（SNR）：信号電力と雑音電力の比。一般に値が大きいほど、雑音に対して信号を識別しやすい。

*3 直交周波数分割多重（OFDM）：多数のサブキャリアを直交する周波数間隔で配置し、並列に情報を伝送する方式。

*4 スペクトル有効周波数分割多重（SEFDM）：OFDM よりサブキャリア間隔を狭くした非直交伝送方式。帯域を有効利用できる一方、自己干渉が生じる。

*5 IQ データ：受信信号を同相成分（I）と直交成分（Q）で表した複素データ。振幅と位相の情報を含む。

*6 スペクトログラム：短時間ごとに求めた周波数成分の電力を並べ、時間と周波数に対する信号の変化を表したもの。

*7 畳み込みニューラルネットワーク（CNN）：局所的な特徴を抽出する処理を重ね、画像や信号に含まれるパターンを学習するニューラルネットワーク。

*8 マルチモーダル CNN：異なる種類・表現の入力から抽出した特徴を統合する CNN。本研究では同じ受信信号の複数の表現を用いる。

*9 フェージング：複数の伝搬経路などの影響で受信信号の振幅や位相が変動する現象。レイリーフェージングは卓越した直接波がない場合を表すモデル。

*10 K ファクタ：ライスフェージングにおける、卓越した直接波成分と散乱波成分の電力比を表す指標。

参考文献

[1] S. Kojima, K. Maruta, and C. Ahn, “Adaptive Modulation and Coding Using Neural Network Based SNR Estimation,” IEEE Access, vol. 7, pp. 183545-183553, 2019.

[2] T. Xu and I. Darwazeh, “A Soft Detector for Spectrally Efficient Systems With Non-Orthogonal Overlapped Sub-Carriers,” IEEE Communications Letters, vol. 18, no. 10, pp. 1847-1850, 2014.

[3] T. Xu and I. Darwazeh, “Experimental Validations on Self Interference Cancelled Non Orthogonal SEFDM Signals,” 2018 IEEE 87th Vehicular Technology Conference (VTC Spring), pp. 1-5, 2018.

[4] S. Mohammadvaliei, M. Sebghati, and H. Zareian, “Adaptive modulation and coding using deep recurrent neural network,” Telecommunication Systems, vol. 81, no. 4, pp. 615–623, 2022.

[5] T. Ngo, B. T. Kelley, and P. Rad, “Deep Learning Based Prediction of Doppler Shift for Mobile Communications,” in 2021 Telecoms Conference (ConfTELE), pp. 1–6, 2021.

[6] S. Kojima, K. Maruta, Y. Feng, C. Ahn, and V. Tarokh, “CNN based Joint SNR and Doppler Shift Classification using Spectrogram Images

for Adaptive Modulation and Coding," IEEE Transactions on Communications, vol. 69, no. 8, pp. 5152-5167, 2021.

[7] K. Tamura, S. Kojima, P. V. Trinh, S. Sugiura, and C. Ahn, "Joint SNR and Rician K-Factor Estimation Using Multimodal Network over Mobile Fading Channels," IEEE Transactions on Machine Learning in Communications and Networking, vol. 2, pp. 766-779, 2024.

[8] S. Kojima, Y. Goto, K. Maruta, S. Sugiura, and C. Ahn, "Timing Synchronization Based on Supervised Learning of Spectrogram for OFDM Systems," IEEE Transactions on Cognitive Communications and Networking, vol. 9, no. 5, pp. 1141-1154, 2023.

この研究は、令和３年度ＳＣＡＴ研究助成の対象として採用され、令和４～６年度に実施されたものです。