

Faster-than-Nyquist 伝送における高精度な通信環境推定手法の開発

研究代表者 小島 駿

東京大学 生産技術研究所

1 はじめに

Beyond 5G や 6G 等の次世代移動体無線通信システムでは、高速・大容量かつ高品質な通信の実現に加え、低消費電力かつ低遅延で大規模な同時接続が可能なシステムが要求されている。そのため、従来広く用いられてきたマイクロ波帯の電波を用いた通信やマクロセル環境だけでなく、ミリ波帯の電波を用いる通信やスモールセル環境といった新たなコンセプトによる通信システムが大きな注目を集めている。加えて、IoT 等の革新的なアプリケーションの発展に伴い、送受信機が高速で移動し通信性能を劣化させるチャネル時変動が発生するような劣悪な環境下においても、高品質な通信が必要とされている[1]。こうした要求やシステムを実現し得る技術として、通信環境に応じて変調方式・符号化率を制御する適応変調符号化 (AMC: adaptive modulation and coding) は広く研究されている[2]。AMC を適用させることで、様々な環境においてそのスループットを最大化することが可能となる。AMC では制御を行うために伝搬環境の情報を事前に取得する必要がある。伝搬環境情報は受信機側で推定しそれを送信機側にフィードバックすることによって制御に利用される。このため、これらの適応制御方式の性能は受信機からのフィードバック情報 (FBI: feedback information) の精度に依存しており、高精度に推定された FBI が必要不可欠である。また特に送受信機が高速で移動するような環境下では、フィードバック遅延が通信性能の劣化の主要な要因となるため、高精度かつ高速な推定処理が要求される。一方で、周波数利用効率の観点からは、増加の一途を辿っている無線データトラフィックの需要に対応するために、これまではより高い周波数帯域を次々と割り当てることで解決してきたが、昨今では利用可能な周波数帯域の逼迫が課題となっており、ミリ波やテラヘルツ波等の超高周波数帯域の利用が検討されている。しかしながら、電波の性質上減衰が大きくカバレッジが狭いという制約がありユースケースが限られてしまう。そのため、従来のマイクロ波帯等の電波資源をより有効活用するための技術として、周波数領域上に信号を圧縮配置する Faster-than-Nyquist (FTN) 伝送方式が注目を集めている[3]。FTN は、従来広く使用されている OFDM とは異なり、信号間の周波数間隔を狭めて重ね合わせることで、同じ占有帯域でより多くのデータを送受信する方式である。周波数利用効率を改善できる一方で、隣接信号間の直交性が崩壊し自己干渉が生じてしまう問題があり、適応的な制御に必要な通信環境情報を取得するには自己干渉除去のための複雑な信号処理が不可欠となってしまう。FTN を実際の通信システムに適用する場合、AMC による適応制御が不可欠であるが、この制御には通信環境情報として信号対雑音電力比 (SNR: signal-to-noise power ratio) が必要となる。実際の AMC では、受信機で推定された SNR に基づいてパラメータが決定され、送信機側にフィードバックされる。多数の AMC パラメータを非常に短い時間間隔で制御する必要がある。制御情報として必要とされる SNR には高速・高精度な推定が要求される。SNR 推定に係わる従来手法は計算量が大いことに加え、チャネルの時変動やフェージング・FTN による自己干渉によって大きく影響を受けるため、このような環境では推定精度が劣化してしまう[4][5]。そこでこれらの問題を解決するために本研究では、畳み込みニューラルネットワーク (CNN: convolutional neural network) を用いて FTN 信号のスペクトログラムから SNR を分類・検出する手法を提案する。受信信号のスペクトログラムとは、信号を短期間フーリエ変換 (STFT: short Time Fourier Transform) したものであり、時間・周波数・電力を

表す 3 次元グラフである。スペクトログラムでは SNR やドップラーシフト等の通信環境の特徴を明確に表現することができ、画像の特徴抽出に長ける CNN と親和性が高い[6]。提案法ではこれらの特性を活かし、FTN の自己干渉の影響が強い場合でも、SNR に紐づく特徴を抽出することで、高精度な SNR 分類を実現する。提案する推定器は、チャンネル等化を必要とせず受信信号データのみを教師信号として学習するため、データセットの取得が容易な点もメリットであり、簡易な構成で高精度・低計算量の推定器を実現できる。シミュレーション結果を通して、提案手法の有効性を様々な環境下における推定精度の観点から評価・検討する。

2 システムモデル

2-1 チャンネルモデル

本稿では伝搬モデルとして時変マルチパスフェージングチャンネルを仮定している[7]。送信帯域幅がチャンネルコヒーレンス帯域幅よりも大きい場合、コヒーレント周波数帯域幅を超える送信信号の周波数成分は、異なる位相遷移および利得を有する。このチャンネルは周波数選択性チャンネルと呼ばれ、そのチャンネルインパルス応答は次のように表される。

$$h(\tau, t) = \sum_{k=0}^{K-1} h_k(t) \delta(\tau - \tau_k) \quad (1)$$

のように表される。ここで K は離散パス数を示し、 h_k は各パスの複素利得を示す。 $\delta(\cdot)$ はディラックのデルタ関数を表し、各タップ係数は次のように表される。

$$h_k(t) = \frac{a_k}{\sqrt{K}} \exp(j(2\pi f_d t \cos\theta_k + \phi_k)) \quad (2)$$

ここで a_k は k 番目の経路の利得、 f_d は最大ドップラー周波数を示す。 θ_k と ϕ_k は k 番目の到来波の到来方向と初期位相を表す。 $\sum_{k=0}^{K-1} \mathbb{E}[|h_k|^2] = 1$ はアンサンブル平均とする。本稿では Jakes モデルに基づいたチャンネルを想定している[8]。OFDM を前提としたとき、周波数応答 $H(t; f)$ は $h(\tau, t)$ の離散フーリエ変換として以下のように表される。

$$\begin{aligned} H(f, t) &= \int_0^{\infty} h(\tau, t) \exp(-j2\pi f\tau) d\tau \\ &= \sum_{k=0}^{K-1} h_k(t) \exp\left(-j2\pi f \frac{k}{B}\right) \end{aligned} \quad (3)$$

ここで B は送信信号の帯域幅である。またマルチパス波である K に関して以下のような関係が成り立つ。

$$K = \lfloor BT_m \rfloor + 1 \quad (4)$$

T_m はマルチパスの最大遅延時間を示す。これらの式より、各チャンネルの利得が異なるためチャンネルの周波数応答は一定ではなくなる。このようなフェージング環境は周波数選択性フェージングと呼ばれる。

2-2 スペクトル有効周波数分割多重 (SEFDM)

本稿では、周波数利用効率を向上させるため、通信方式には FTN 伝送の一種である spectral efficient frequency division multiplexing (SEFDM)を想定している。SEFDM 信号は OFDM 信号と同様に、それぞれ 1 つの非直交サブキャリアで変調されたシンボルのストリームから構成される。送信信号 $x(t)$ は次のように表される[9].

$$x(t) = \frac{1}{\sqrt{T}} \sum_{p=-\infty}^{\infty} \sum_{q=0}^{Q-1} s_{p,q} \exp\left(\frac{j(2\pi q\alpha(t-pT))}{T}\right) \quad (5)$$

T は SEFDM 信号のシンボル長、 Q はサブキャリア数を表す。また $s_{p,q}$ は、 p 番目の SEFDM シンボルの q 番目のサブキャリアを示す。 α は圧縮率を示し、次のように表される。

$$\alpha = \Delta f T, \quad \text{with } \alpha < 1 \quad (6)$$

Δf はサブキャリア間隔を表す。ここで $\alpha = 1$ の時、OFDM 信号となる。この時、離散 SEFDM 信号は、 T/Q' の間隔でオーバーサンプリングすることによって表せる。ここでは $Q' = \rho Q$ であり、 ρ はオーバーサンプリング係数である。0番目のシンボルの離散 SEFDM 信号は次のようになる。

$$X[l] = \frac{1}{\sqrt{Q'}} \sum_{q=0}^{Q-1} s_q \exp\left(\frac{j(2\pi q l \alpha)}{Q'}\right) \quad (7)$$

ここで、 $l = 0, 1, \dots, Q' - 1$ であり、 $1/\sqrt{Q'}$ はスケーリング係数である。この離散信号の行列表現は次のように表される。

$$X = \Psi S \quad (8)$$

X は式(5)の時間サンプルベクトルであり、 $X = [x_0, \dots, x_{Q'-1}]^T$ と表される。また S は $S = [s_0, \dots, s_{Q-1}]^T$ の送信信号である。ここで、 ΨS は $Q' \times Q$ のサブキャリア行列を表し、その要素は次のようになる。

$$\Psi_{l,q} = \frac{1}{\sqrt{Q'}} e^{\frac{j2\pi q l \alpha}{Q'}} \quad (9)$$

受信側では SEFDM 信号は式(3)で表現されるフェージングと加法性白色ガウス雑音(AWGN: additive white Gaussian noise)の影響を受け、次のように表される。

$$R = \Psi^* H X + \Psi^* N = \Psi^* H \Psi S + N_{\Psi^*} \quad (10)$$

ここで R は $Q' \times Q'$ 次元の復調信号であり、 Ψ^* は Ψ の共役転置、 N は AWGN である。理想的なチャネル推定・等化処理を想定した場合、式(10)は次のように書き換えられる。

$$R = \Psi^* \Psi S + N_{\Psi^*} = C S + N_{\Psi^*} \quad (11)$$

C は $Q' \times Q'$ の相関行列であり、 $C = \Psi^* \Psi$ で定義される。またその要素は次のように表される[10].

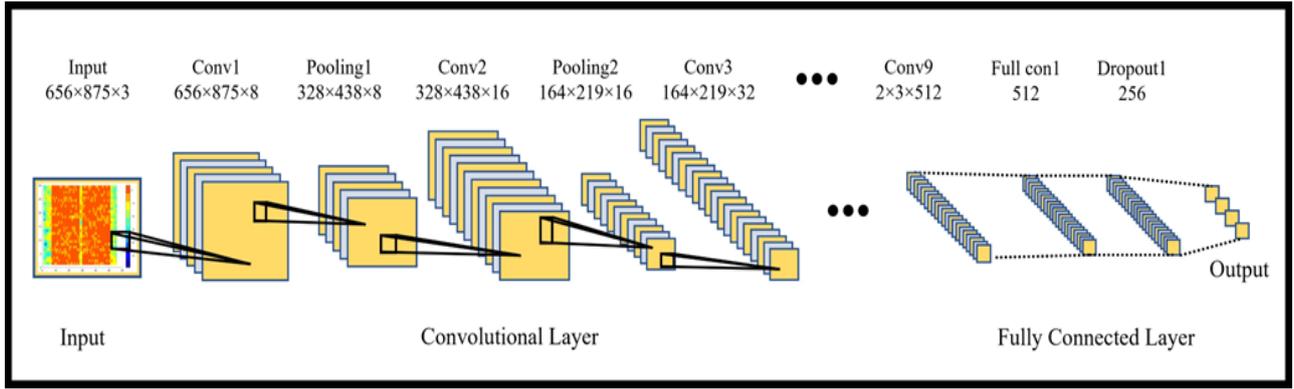


図 1: Concept of the proposed SNR estimation by the convolutional neural network.

$$\mathbf{C}(u, w) = \frac{1}{Q'} \begin{cases} Q', u = w \\ \frac{1 - e^{j2\pi\alpha(u-w)}}{j2\pi\alpha(u-w)}, u \neq w \\ 1 - e^{-j2\pi\alpha(u-w)}, u \neq w \end{cases} \quad (12)$$

ここで、 \mathbf{C} は Toeplitz かつ Hermitian 行列であり、その対角成分は自己相関で全て1となり、非対角成分はシンボル間干渉(ICI: inter-carrier interference)を意味する相互相関を表す。SEFDM では OFDM に対し、信号を圧縮するため直交性の崩壊が生じ、自己干渉となる ICI が発生してしまう。この ICI により高精度な通信環境の推定が困難となっている。

3 提案手法

本稿では、受信側で参照信号を用いずに容易に取得できるスペクトログラムに着目し、機械学習を適用することで、干渉が存在する SEFDM 信号において SNR の特徴を抽出し、これを用いて SNR 推定 (分類) を行っている。図 1 に提案法の概要図を示す。高精度な SNR の推定を実現するために、提案法ではスペクトログラムと親和性が高く、特徴抽出能力に優れる CNN を適用している。

3-1 スペクトログラム

図 2 に様々な通信環境下におけるスペクトログラムの例を示す。スペクトログラムは、受信した信号を窓関数に通し、離散フーリエ変換 (DFT: discrete Fourier transform) を行って得られる周波数スペクトルであり、時間、周波数、信号電力の 3 次元要素で表される。この窓関数を用いた一連のフーリエ変換を短時間フーリエ変換 (STFT: short time Fourier transform) という。窓関数は特定の有限区間の外側でゼロになる関数であり、この関数を乗じた受信信号 r' は、次のように表される。

$$r'(t - t_s) = r(t) w_a(t - t_s) \quad (13)$$

$$w_a(t - t_s) \neq 0 \quad \text{for } t_s \leq t \leq T + t_s - 1 \quad (14)$$

ここで r は受信信号、 t_s は時間領域のフレームシフトを表し、 w_a は窓関数を、 T はフレーム長を表す。STFT は、この有限区間信号 r' に対して DFT を行うことで定義され、次のように表される。

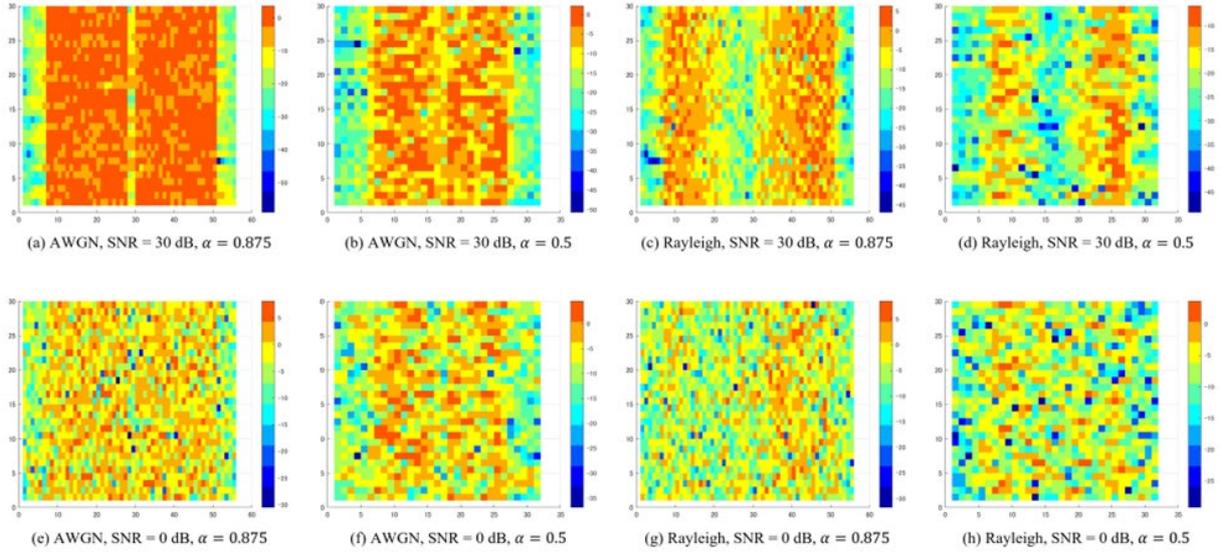


図 2: Spectrograms according to various compression factors and fading

$$\begin{aligned}
 R(f, t) &= \sum_{t=t_s}^{T+t_s-1} r(t) w_a(t - t_s) \exp\left\{\frac{-j2\pi f(t - t_s)}{T}\right\} \\
 &= \sum_{t=-\infty}^{\infty} w_f(t_s - t) r(t)
 \end{aligned} \tag{15}$$

ここで

$$w_f(t) = \begin{cases} w_a(-t) \exp\left\{\frac{j2\pi ft}{T}\right\}, & 1 - T \leq t \leq 1 \\ 0, & \text{otherwise} \end{cases} \tag{16}$$

ここで, $R(f, t)$ は複素数要素を持つ信号である. 信号の電力を示すスペクトログラム $P(f, t)$ は次のように表される.

$$P(f, t) = |R(f, t)|^2 \tag{17}$$

本稿では窓関数として以下に示す矩形窓関数を用いている.

$$w_a(t) = 1 \quad \text{for } 0 \leq t \leq T - 1 \tag{18}$$

上述のように, 簡単な計算処理のみでスペクトログラムを取得することが可能である. また図 2 と式(17)から, スペクトログラムは信号の全シンボルに渡って電力分布を示しており, フェージングによる電力の歪みに時間的な相関があることが確認できる. さらに式(12)で表されているように, SEFDM における自己干渉の影響が, 電力の変動としてスペクトログラム中に現れていることが確認できる. 提案法では, 特徴抽出能力に優れた CNN を用いてこの特徴量を学習させることで, 干渉の除去を必要としない高精度な SNR の分類を実現している.

3-2 畳み込みニューラルネットワーク

近年, 様々な分野で CNN による画像分類が目覚ましい成果をあげている. 特に無線通信では, CNN による変調方式分類が広く研究されており, 信号データから特徴量を抽出して CNN により変調方式を分類するア

ルゴリズムが有効であることが明らかとなっている. 本稿では, この CNN で AMC の制御に必要な通信環境情報である SNR の推定 (分類) を行うことに焦点を当てている. CNN の性能を最大限に発揮させるために, 通信路の様々な特徴を含むスペクトログラムを 3 次元 RGB 画像に変換し入力画像として用いて, これを分類問題として通信環境情報推定に近似させた CNN ベースの推定手法を提案する. CNN の伝達関数は次のように記述できる.

$$y_i = f \left(\sum_{i=1}^I w_{ij} \cdot x_i + b_j \right) \quad (19)$$

y_i は I 層からの出力, w_{ij} と b_j は i 層から j 層への入力に対する重みと j 層でのバイアスをそれぞれ示す. ここで f は以下に示す活性化関数を示す.

$$f_{ReLU}(x_i) = \begin{cases} x_i, & x_i < 0 \\ 0, & x_i \geq 0 \end{cases} \quad (20)$$

$$f_{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{m=1}^M e^{x_m}} \quad (21)$$

提案法で用いている CNN の構成は図 1 に示す. 9 層の畳み込み層と 8 層のプーリング層, 2 層の全結合層から構成され, 活性化関数は最終層以外では Rectified Liner Unit (ReLU), 最終層では softmax 関数を使用している. 提案法は, オフライン学習で受信スペクトログラムと SNR の関係性を学習し, オンラインフェーズで未知の入力スペクトログラムからこれらの値を分類 (推定) する.

4 シミュレーション評価

4-1 シミュレーションパラメータ

シミュレーション環境として Windows10, Intel(R) Core(TM) i9-10900K CPU を使用し, GPU は NVIDIA 社の GeForce RTX 3090 を用いた. 学習に用いた受信スペクトログラムのデータセットは MATLAB を用いて表 1 に示すシミュレーションパラメータに基づいて作成した. ネットワークの学習には, スペクトログラムの画像を各分類ラベルに対して 1000 枚使用し学習させ, 入力として未知のスペクトログラム画像を入れた場合にそれぞれのラベルを推定し, 対応する分類ラベルの値を出力するような学習を行った. 学習に使用するデータとしては, シミュレーションにより生成した 1000 個のスペクトログラム画像のうちランダムな 90%を

表 1: シミュレーションパラメータ

Transmission scheme	SEFDM
Compression factor α	0.5, 0.625, 0.75, 0.875, 1
Fading	AWGN, Rayleigh fading
GI length	16 sample times
FFT size	64
Frame size	32 symbols ($N_p = 2, N_d = 30$)
Data Modulation	QPSK
Maximum Doppler shift	0.001 Hz

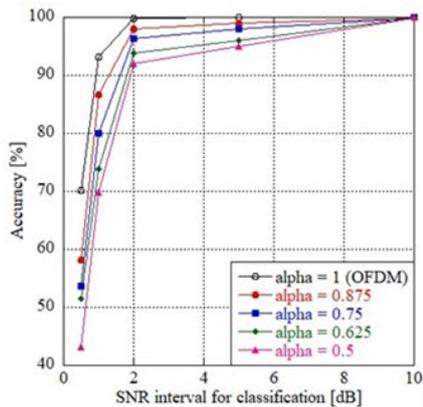


図 3: Various α in AWGN

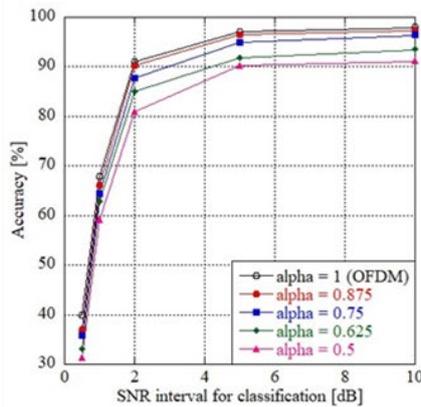


図 4: Various α in Rayleigh

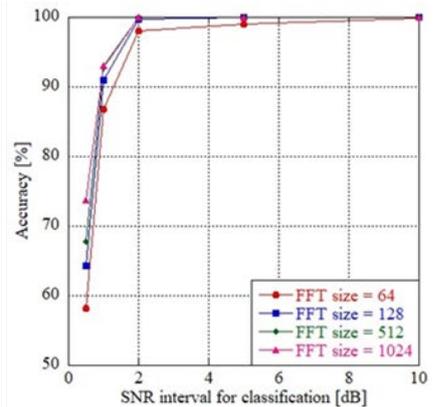


図 5: Various FFT in AWGN

使用し、残りの10%をテストデータとした。学習率は初期値を0.001と設定し、学習エポックごとの反復は30回として学習を行った。

4-2 SEFDM 信号における SNR の分類結果

図 3 に、AWGN チャネルにおいて様々な圧縮率の SEFDM のスペクトログラムに提案法を用いた SNR の分類精度を示す。ここでは、4 種類の SNR のスペクトログラムを推定する 4 パターンの分類問題における分類精度を示している。横軸は分類する SNR の間隔を表す。このグラフから、AWGN チャネルにおいては特に圧縮率が 1 の通常の OFDM の場合、全ての領域で 70%を上回っており、スペクトログラムと CNN を用いる SNR 分類の有効性が明確となっている。一方で、提案法を用いて SEFDM 信号から SNR を推定する場合、SEFDM の圧縮率が小さくなるにつれて推定精度が劣化することが確認できる。これは圧縮率が小さいほど、自己干渉の影響が大きくなることが要因として挙げられる。しかしながら、圧縮率が 0.5 の場合でも、SNR の間隔が 2dB で約 92%の精度を達成しており、提案法を用いることで SEFDM の自己干渉の影響によらず高い精度で SNR を分類することが可能であることが明らかとなっている。

図 4 に、レイリーフェージングチャネルにおける圧縮率を変化させた場合の SNR の分類精度を示す。図 3 のケースと同様に 4 パターンの分類問題で分類する SNR の間隔を変化させた場合の分類精度としている。ここでフェージングのパラメータとして、パス数は 3 で、遅延プロファイルは指数減衰型、ドップラーシフトは 0.001Hz としている。このグラフから、AWGN チャネルと同様に圧縮率が小さくなるにつれて分類精度が劣化していることが確認できる。高 SNR 環境では、フェージングの影響がより顕著になるため、分類間隔が大きい場合で AWGN チャネルの場合と比較し推定誤りが増加する。また一方で圧縮率が 0.5 の場合でも、SNR の間隔が 2dB で約 8%の精度を達成しており、マルチパスフェージング環境においても自己干渉の除去やチャネル推定・等化処理を行わずとも高い精度で分類可能なことが確認できる。

図 5, 6 に、AWGN チャネル、レイリーフェージングチャネルにおいて FFT サイズを変化させた場合の SNR 分類結果を示す。ここでは圧縮率は 0.875 としている。これらのグラフから、AWGN チャネル、レイリーフェージングチャネルどちらにおいても、FFT サイズを大きくすると分類精度が向上することが確認できる。FFT サイズを大きくすることで、SNR の特徴を含有するサブキャリアの数が増加し、画像中の抽出可能な特徴量が増加するため、分類精度が向上する。本稿では、CNN の入力としているスペクトログラム画像のサイ

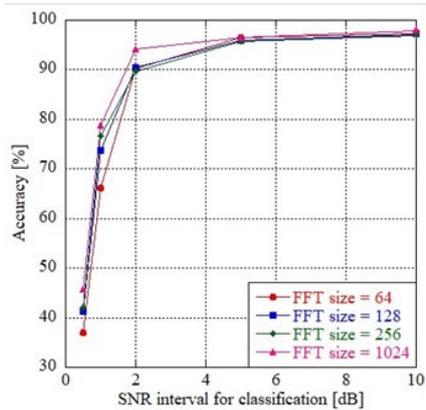


図 6: Various FFT in Rayleigh

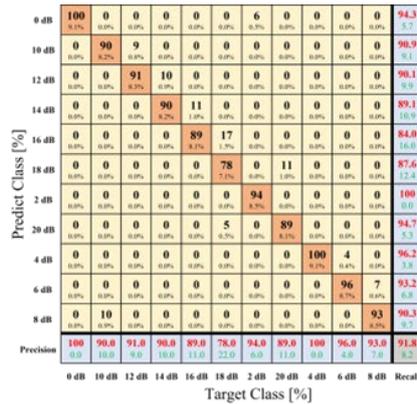


図 7: 混同行列 (AWGN)

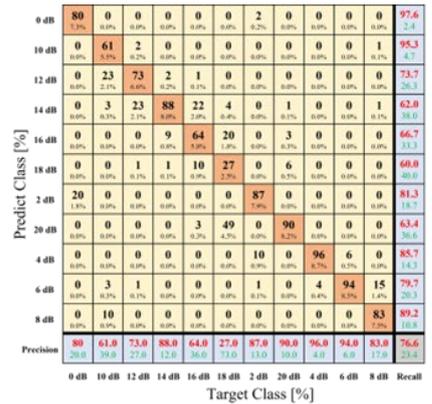


図 8: 混同行列 (Rayleigh)

ズは656 × 875 × 3で固定しており、FFT のサイズによって計算量は変化しない。分類する SNR が 2dB 間隔の場合で AWGN、レイリーフェージングどちらの場合でも、FFT サイズによらず精度は 90%を超えており、高精度な特徴抽出・分類が実現できていることが明らかとなっている。

図 7, 8 に、AWGN とレイリーフェージングチャネルにおいて、圧縮率 0.875, FFT サイズ 64, SNR の間隔が 2dB で 0 から 20dB まで、それぞれ 11 パターンの SNR を分類した場合の混同行列を示す。縦軸が学習した CNN により予想したクラス、横軸が実際のクラスとなっている。AWGN チャネルでは、ほぼ全ての SNR で 90%を超える精度で分類ができており、全体の分類精度も約 92%と非常に高い値となっている。一方でレイリーフェージングチャネルでは、フェージングの影響を受け全体的に AWGN チャネルよりも分類精度が劣化している。フェージングによる影響はスペクトログラム中に電力の歪みとして現れる。そのため、低 SNR 領域では雑音による影響の方が大きくフェージングの影響は埋もれてしまうが、高 SNR 領域では雑音の影響はほとんどないためこのフェージングにより推定誤りが生じ精度が劣化している。

まとめ

本稿では、受信した SEFDM 信号のスペクトログラムから CNN を適用することで、干渉の除去を行わずに、適応的な制御に必要な不可欠な通信環境情報である SNR を高精度に推定 (分類) する手法を提案した。信号を圧縮することで周波数利用効率を向上させる SEFDM では、その自己干渉が課題となる。この課題に対し、通信環境の特徴を明確に表現可能なスペクトログラムと特徴抽出能力に優れる CNN を適用した場合の分類精度の検討を行った。様々な圧縮率、FFT サイズにおける AWGN、レイリーフェージングチャネル環境においてシミュレーションを行った結果、提案法を適用することで参照信号を用いずにかつ干渉の除去も行わずとも、SNR の分類を高い精度で実行可能なことを明らかにした。

【参考文献】

- [1]. W. Saad, M. Bennis, and M. Chen, "A Vision of 6G Wireless Systems: Applications, Trends, Technologies, and Open Research Problems," /it IEEE Network, vol. 34, no. 3, pp. 134-142, June 2020.
- [2]. S. Kojima, K. Maruta, and C. Ahn, "Adaptive Modulation and Coding Using Neural Network Based SNR Estimation," IEEE Access, vol. 7, no. 1, pp. 183545-183553, 2019.
- [3]. S. V. Zavjalov, S. V. Volvenko, and S. B. Makarov, "A Method for Increasing the Spectral and Energy

- Efficiency SEFDM Signals," IEEE Communications Letters, vol. 20, no. 12, pp. 2382-2385, Dec. 2016.
- [4]. F. Bellili, A. Methenni, and S. Affes, "Closed-Form CRLBs for SNR Estimation from Turbo-Coded BPSK-MSK- and Square-QAM-Modulated Signals," IEEE Transactions on Signal Processing, vol. 62, no. 15, pp. 4018-4033, Aug. 2014.
- [5]. W. Wang, Y. Shen, and Y. Wang, "Low-Complexity NonData-Aided SNR Estimation for Multilevel Constellations," IEEE Communications Letters, vol. 20, no. 12, pp. 113-116, Jan. 2020.
- [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, May 2021.
- [7]. E. Biglieri, J. Proakis, and S. Shannai, "Fading channels: Information-theoretic and communication aspects," IEEE Transactions on Information Theory, vol. 44, no. 6, pp. 2619-2692, Jan. 1998.
- [8]. L. Cimini, "Analysis and simulation of a digital mobile channel using orthogonal frequency division multiplexing", IEEE Trans. Commun., vol. 33, no. 7, pp. 665-675, Jul. 1985.
- [9]. T. Xu and I. Darwazeh, "A Soft Detector for Spectrally Efficient Systems With Non-Orthogonal Overlapped SubCarriers," IEEE Communications Letters, vol. 18, no. 10, pp. 1847-1850, Oct. 2014.
- [10]. 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.

〈 発 表 資 料 〉

題 名	掲載誌・学会名等	発表年月
Towards Deep Learning-Guided Multiuser SNR and Doppler Shift Detection for Next-Generation Wireless Systems	IEEE 95th Vehicular Technology Conference (VTC 2022 - Spring)	2022 年 6 月
スペクトル有効周波数分割多重における深層学習を用いた通信環境推定の検討	電子情報通信学会 無線通信システム研究会	2022 年 11 月
Timing Synchronization Based on Supervised Learning of Spectrogram for OFDM Systems	IEEE Transactions on Cognitive Communications and Networking	2023 年 5 月