

多入力多出力チャネルのニューラル推定に関する一検討

1200321 塩田 慎也 【ワイヤレスネットワーク研究室】

1 はじめに

近年、無線通信分野において機械学習の応用研究が広がりを見せている。代表的な主要技術である多入力多出力 (multiple-input multiple-output: MIMO) システムで最良の性能が得られる最尤 (maximum likelihood: ML) 推定法には、送受信アンテナ数が増大すると計算量が指数関数的に増大するという問題がある [1]。従来の ZF (zero-forcing), 最小平均 2 乗誤差 (minimum mean squared error: MMSE) 推定法による推定精度は、ML 推定法に比べ著しく劣るため、ML 推定と ZF, MMSE 推定の間に位置する推定法の開発が求められており、文献 [2] ではニューラルネットワークに基づく MIMO 検出器が検討されている。本研究では、MIMO 通信路におけるニューラル推定の性能を従来の方法と比較し検討する。

2 MIMO

2.1 受信信号

送信側に N 本、受信側に L 本のアンテナを有する MIMO を考える。送信メッセージを $\mathbf{s} \in \{+1, -1\}^N$, 受信信号を $\mathbf{y} \in \mathbb{R}^L$ とすると、 \mathbf{y} は次式となる。

$$\mathbf{y} = \mathbf{H}\mathbf{s} + \mathbf{n} \quad (1)$$

ここで、 $\mathbf{H} \in \mathbb{R}^{L \times N} (L \geq N)$ はチャネル行列、 $\mathbf{n} \in \mathbb{R}^L$ は加法性白色ガウス雑音 (additive white Gaussian noise: AWGN) である。

2.2 従来のメッセージ推定法

主な従来の推定法として、ZF 推定法と MMSE 推定法を用いる。ZF, MMSE 推定を用いた \mathbf{s} の推定値 $\hat{\mathbf{s}}_{\text{ZF}}$, $\hat{\mathbf{s}}_{\text{MMSE}}$ は次式となる。

$$\hat{\mathbf{s}}_{\text{ZF}} = \mathbf{W}_{\text{ZF}}^T \mathbf{y} \quad (2)$$

$$\hat{\mathbf{s}}_{\text{MMSE}} = \mathbf{W}_{\text{MMSE}}^T \mathbf{y} \quad (3)$$

ここで、上付き文字 $(\cdot)^T$ は転置を示している。重み \mathbf{W}_{ZF}^T , $\mathbf{W}_{\text{MMSE}}^T$ は次式で与えられる。

$$\mathbf{W}_{\text{ZF}}^T = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (L \geq N) \quad (4)$$

$$\mathbf{W}_{\text{MMSE}}^T = (\mathbf{H}^T \mathbf{H} + \sigma^2 \mathbf{I}_N)^{-1} \mathbf{H}^T \quad (L \geq N) \quad (5)$$

ここで、 \mathbf{I}_N は単位行列、 σ^2 はガウス雑音の分散である。

2.3 ニューラルメッセージ推定法




図1 一層分のフローチャート

図1は線形層と活性化関数からなるニューラル推定器一層分のフローチャートである。各層の出力は次の層の入力となる。図1の入出力の関係は次式で与えられる。

$$\mathbf{q}_1 = \mathbf{y} \quad (6)$$

$$\mathbf{q}_{k+1} = g_k(\mathbf{W}_k \mathbf{q}_k + \mathbf{b}_k) \quad (k = 1, \dots, K-1) \quad (7)$$

$$\hat{\mathbf{s}} = g_K(\mathbf{W}_K \mathbf{q}_K + \mathbf{b}_K) \quad (8)$$

ここで、 g_k は $1 \leq k \leq K-1$ に対して ReLU 関数、 $k = K$ に対して tanh 関数とする。重み行列 $\mathbf{W}_k (k = 1, \dots, K)$, バイアスベクトル $\mathbf{b}_k (k = 1, \dots, K)$ は学習可能パラメータである。損失関数は推定信号 $\hat{\mathbf{s}}$ と送信信号 \mathbf{s} の平均 2 乗誤差を用いる。

3 性能評価

MIMO システムのアンテナ数は送受信共に $L = N = 4$ とし、各アンテナの受信機は対応するアンテナから送信された信号に同期しているものとする。深層ネットワークとして 3 層モデル ($K = 3$), 隠れ層のユニット数を 50, 最適化には学習率 0.001 の Adam を用いる。ミニバッチサイズを 200, 学習回数を 10000 回としたときの BER 特性を図 2 に示す。図 2 より、ニューラル (neural network: NN) 推定法は ML 推定法に近い BER 特性が得られ、他の従来の推定法より大幅に BER 特性が改善されていることが確認できる。




図2 BER 特性

4 まとめ

本研究では、MIMO 通信路においてニューラル推定を行うことで、ML 推定に近い BER 特性が得られ、ZF, MMSE 推定の BER 特性を大幅に改善できることを示した。

参考文献

- [1] 和田山 正, “無線通信のための深層学習の基礎,” 電子情報通信学会通信ソサイエティ, Oct. 2019.
- [2] N. Samuel, T. Diskin, and A. Wiesel, “Learning to detect,” IEEE Trans. Signal Process., vol. 67, no. 10, pp. 2554-2564, May 2019.