

M-014

無線信号の可視化情報を用いた深層学習による干渉レベル推定

Blind Interference Estimation by Machine Learning Using Visualized Wireless Signal Information

丸田 一輝¹
Kazuki Maruta小島 駿¹
Shun Kojima中山 悠^{2,3}
Yu Nakayama久野 大介⁴
Daisuke Hisano安昌俊¹
Chang-Jun Ahn

1. はじめに

モバイルトラフィックの増大に伴い、無線通信における電波干渉は深刻な問題となりつつある。これを克服するためには、同一チャネル干渉を効果的に抑圧する必要がある。アレーアンテナ技術はそれを可能とする。そのためには一般にチャネル状態を、送受信側で既知であるトレーニング信号等を用いて事前に把握する必要がある一方、把握すべき信号の増大に伴いオーバーヘッドも増大する。加えて異なるシステム間では信号の型式も異なることからトレーニング信号を共有できないため干渉抑圧は困難である。ここでチャネル推定が不要なブラインド型アダプティブアレー(BAA) [1][2]が有効であるが、アンテナ入力段における信号対干渉電力比(SIR)により適用すべきアルゴリズムが異なる。そのため干渉レベルに応じた適切なアルゴリズムの切り替えが必要となる。これを実現するために本稿では、干渉レベルを事前に推定する手法としてコンスタレーション画像を用いた畳み込み多層ニューラルネットワークによるSIRの識別手法を提案し、その可能性を検証する。

2. システムモデル

2.1 システム構成

本稿において、 $|\cdot|$, $(\cdot)^T$, 及び $(\cdot)^H$ は絶対値、転置、複素共役転置をそれぞれ示す。 N_t , N_r , 及び N_s をそれぞれ送信局数、受信アンテナ数、データシンボル数とし、各送信局は1アンテナのみ備えるものとする。図1にシステムモデルを示す。本検討では平面波近似による伝搬モデルを仮定する。チャネル行列 $\mathbf{H} \in \mathbb{C}^{N_r \times N_t}$ の各係数は到来角度 θ により与えられる。 $\mathbf{s}_j \in \mathbb{C}^{N_s \times N_s}$ は第 j ($1 \leq j \leq N_t$) 端末局からの送信信号、 $\mathbf{X} \in \mathbb{C}^{N_r \times N_s}$ は受信信号つまりアレー入力であり、 k ($1 \leq k \leq N_s$)はシンボルの番号を表す。以上から構成される送信信号ベクトル $\mathbf{S} = (\mathbf{s}_1^T, \dots, \mathbf{s}_t^T, \dots, \mathbf{s}_{N_t}^T)^T \in \mathbb{C}^{N_r \times N_s}$ 及び受信信号ベクトル \mathbf{X} の関係は以下のように表される。

$$\mathbf{X} = \mathbf{H}\mathbf{S} + \mathbf{N} \quad (1)$$

ここで、 \mathbf{H} の各要素は $\exp\{-j2\pi(i-1)d \cos \theta_j\}$ であり、第 j 送信局から第 i 受信アンテナへのチャネル係数を表す。 $\mathbf{G} \in \mathbb{C}^{N_r \times N_t}$ は対角要素行列であり、信号源ごとの強度 g_j で与えられる。 $\mathbf{N} \in \mathbb{C}^{N_r \times N_s}$ は白色雑音である。受信ウェイト $\mathbf{w} \in \mathbb{C}^{N_r \times 1}$ は次節にて示すそれぞれのアルゴリズムから受信信号 \mathbf{X} を用いて導出され、これを \mathbf{X} に乗算することでアレー出力 $\mathbf{y} = \mathbf{w}^H \mathbf{X}$ を得る。




図1 システム構成

2.2 ブラインドアルゴリズム

ブラインドアルゴリズムは多数存在するが、ここでは相反する特徴を有するCMAとPIを取り上げる。

2.2.1 定包絡線アルゴリズム(CMA)

CMA [2]は干渉で歪んだアレー出力 \mathbf{y} の振幅を一定値とするようにウェイトを最適化する。その導出基準はいくつか存在するが、呼ばれ良好な収束性を示すLS-CMA [1]によるウェイトは次式により求められる。

$$\mathbf{y} = \mathbf{w}_{\text{CMA}}^H(m) \mathbf{X} \quad (2)$$

$$e_k = y_k / |y_k| \quad (3)$$

$$\mathbf{w}_{\text{CMA}}(m+1) = (\mathbf{X}\mathbf{X}^H)^{-1} \mathbf{X} \mathbf{e}^H \quad (4)$$

2.2.2 電力比反転(PI)

PI [2]は受信信号のSIRを反転するように動作するアルゴリズムである。その性質から、干渉波の電力が大きいほど強い干渉抑圧特性を得られる。PIによるウェイトは受信信号の自己相関行列 $\mathbf{X}\mathbf{X}^H$ から次式のように求められる。

$$\mathbf{w}_{\text{PI}} = \left(\frac{1}{N_s} \mathbf{X}\mathbf{X}^H \right)^{-1} \mathbf{c} \quad (5)$$

$\mathbf{c} = (1 \ 0 \ \dots \ 0)^T$ は拘束ベクトルと呼ばれる。

ここで、CMAとPIの特性を把握するための簡易評価として、受信アンテナ数 $N_r=2$ とし、2つのQPSK信号が受信される場合の両アルゴリズムによる入力SIRと出力SINRの関係を図2に示す。評価諸元は図中に示す。CMAはSIR > 0 dBにおいて所望信号を同位相合成することによ

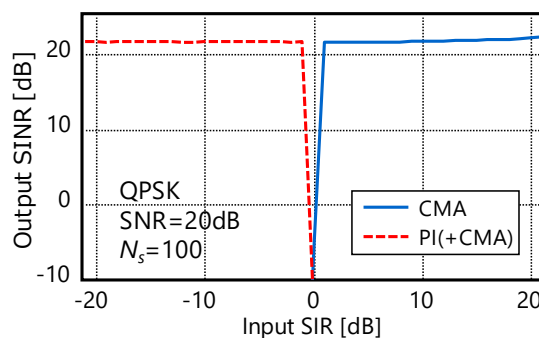


図2 入力SIRに対するアレー出力SINR

¹ 千葉大学 大学院 工学研究院,
Graduate School of Engineering, Chiba University

² 東京農工大学 工学研究院
Institute of Engineering,
Tokyo University of Agriculture and Technology

³ NPO neko 9 Laboratories

⁴ 大阪大学 大学院 工学研究科,
Graduate School of Engineering, Osaka University




図3 畳み込みニューラルネットワークの構成

り利得を向上するため、入力 SIR よりも大きい出力 SINR が得られるが、 $SIR < 0$ dB においては干渉信号に対して動作するため、出力 SINR は低下する。一方、PI は入力 SIR が反転される形で出力されており、干渉信号のレベルが大きいほど高い出力 SINR が得られる。このように、CMA と PI は入力 SIR に対し相反する出力を得ることがわかる。

3. 提案方式：コンスタレーションによる干渉推定

上述した2つのブラインドアルゴリズムを、SIR に応じて切り替えることができれば、いかなる大きさの干渉でも抑圧可能となる。そのためには SIR を受信信号から推定する必要がある。本稿では受信信号のコンスタレーションから SIR を推定することを提案し、その手段として深層学習を適用する。図1に希望信号と干渉信号が重畳されたコンスタレーションの例を示す。希望信号が大きい場合にはコンスタレーションのばらつきは小さく、一方、干渉信号が大きい場合にはそのばらつきは大きくなる。このように SIR によってコンスタレーションの様子が異なることから、これを特徴量として抽出し学習することで SIR の推定が可能になると考えられる。

深層学習として、畳み込みニューラルネットワーク (CNN) [3] を適用する。これは、特に画像に対して優れた識別精度を実現することが知られている。学習データとしては受信信号のコンスタレーションを画像として出力し、これを CNN の入力とする。このように、受信信号を可視化し、深層学習を用いることで内在する情報を得ることが可能となる。その他の応用としては、スペクトル画像を用いた雑音レベルの推定等が考えられる[4]。

4. シミュレーション評価

4.1 条件

学習データとして SIR が異なる条件において、16QAM の希望信号と干渉信号をそれぞれ1つずつ、位相回転をランダムに与えながら合成したコンスタレーション画像 (220×220 ピクセル) を作成した。このとき希望信号の振幅を1とし、受信 SNR は 30dB とした。本検討では SIR が 0 dB より大きいから否かを判別する2クラス分類の精度を

評価する。CMA, PI の選択的適用という観点からはこれが可能であれば十分である。SIR が負の領域で -2.5, -1.5, -0.5 dB, 正の領域で +0.5, +1.5, +2.5 dB のデータを用い、クラス毎に 3500 枚を学習データとした。検証用には 1200 枚を用い、正答率を評価する。シミュレーション環境は MATLAB® (Deep learning toolbox), GPU は NVIDIA® GeForce GTX 1060 6GB を使用した。CNN の構成を図3に

表1 SIR推定結果

SIR[dB]	-3	-2.5	-2	-1.5	-1	-0.5	0	0.5	1	1.5	2	2.5	3
精度 [%]	100	100	100	99.8	96.5	83.7	41.8	81.9	96.8	99.0	99.8	99.9	100

示す。Max pooling, Batch normalization 等の処理を含む15層で構成される。最適化アルゴリズムはモーメンタム項付き確率的勾配降下法 (SGDM) である。

4.2 評価結果

各ケースにおける SIR 推定結果を表1に示す。SIR = 0 dB を除き 80% を超える正答率を達成できていることがわかる。パラメータや学習データの調整等により改善の余地はあるものと思われるが、提案手法による干渉推定の有効性が確認できた。今後は、この結果をもとに、ブラインドアルゴリズムの選択適用による干渉抑圧効果を検証する。

また上記の評価は、希望信号電力が固定的である等、多くの理想的な条件を仮定している。実際には、希望信号/干渉信号の絶対的な受信レベルも未知であり、受信機ではそれらの受信レベルに応じた自動利得制御 (AGC) が動作するため、コンスタレーションのばらつきは異なるものと思われる。また、到来する信号の波数や変調方式、タイミングも様々であり、様々な要因を考慮した場合の本提案アプローチの有効性を検討する必要がある。

5. まとめ

異なる性質を持つブラインドアダプティブアレーアルゴリズムを選択的に適用可能とするために、深層学習によるコンスタレーション画像を用いた干渉レベルの推定手法を提案した。2信号が到来する環境において、80%以上の精度で干渉信号が大きい/小さいを識別可能であり、提案手法の可能性を確認した。

謝辞

本研究の一部は、KDDI 財団の助成を受けて行われた。

参考文献

- [1] B. Agee, "The least-squares CMA: A new technique for rapid correction of constant modulus signals," in *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '86)*, vol. 11, pp. 953-956, Apr. 1986.
- [2] R.T. Compton, Jr. "The Power-Inversion Adaptive Array: Concept and Performance," *IEEE Trans. on Aerospace and Electronic Systems*, vol. AES-15, no.6, pp. 803-9814, Nov. 1979.
- [3] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998.
- [4] 小島, 丸田, 安, "畳み込みニューラルネットワークを用いた SNR 推定法," *信学技報*, vol. 119, RCS2019-xx, 2019年7月.