



Title	深層学習を用いた電波の到来方向推定
Author(s)	加瀬, 裕也
Degree Grantor	北海道大学
Degree Name	博士(工学)
Dissertation Number	甲第15077号
Issue Date	2022-03-24
DOI	https://doi.org/10.14943/doctoral.k15077
Doc URL	https://hdl.handle.net/2115/85378
Type	doctoral thesis
File Information	Yuya_Kase.pdf



博士論文

深層学習を用いた電波の到来方向推定

DOA Estimation of Radio Signals with Deep Learning

加瀬 裕也

深層学習を用いた電波の到来方向推定

2022年3月

北海道大学 大学院情報科学院 情報科学専攻
メディアネットワークコース インテリジェント情報通信研究室

加瀬 裕也

目次

1	序論	7
1.1	研究背景	7
1.2	本論文の目的	9
1.3	本論文の構成	10
	参考文献	13
2	アレーアンテナを用いた到来方向推定	17
2.1	はじめに	17
2.2	アレーアンテナの受信データ相関行列	18
2.3	メインローブ走査による到来方向推定	21
2.3.1	beamformer 法	21
2.3.2	Capon 法	25
2.4	受信データ相関行列の固有構造	27
2.5	MUSIC による到来方向推定	30
2.5.1	Spectral-MUSIC	30
2.5.2	Root-MUSIC	31
2.6	到来方向推定における Cramér-Rao Bound	34
2.7	まとめ	36

参考文献	38
3 整数角度における深層学習の適用可能性の検討	41
3.1 はじめに	41
3.2 DNN の定式化	41
3.3 訓練の枠組み	45
3.4 誤差逆伝播法	46
3.5 到来方向推定への適用	49
3.6 推定精度の評価	50
3.6.1 シミュレーション条件	50
3.6.2 訓練データの SNR と学習曲線	53
3.6.3 訓練データの SNR と推定精度	57
3.6.4 推定誤差の累積確率	60
3.6.5 近接波の推定に特化した DNN	60
3.6.6 汎用 DNN と専用 DNN を用いた並列推定	62
3.7 まとめ	65
参考文献	66
4 実数角度における深層学習の適用可能性の検討	69
4.1 はじめに	69
4.2 Batch Normalization	69
4.3 DNN の到来方向推定への適用方法	70
4.4 推定精度の評価	71
4.4.1 シミュレーション条件	71
4.4.2 DNN パラメータの比較	73
4.4.3 推定精度の比較	75
4.4.4 グリッド境界の問題を解決する提案手法	81
4.4.5 提案手法の評価	83

4.4.6	近接波推定	89
4.4.7	DNN A, DNN B, DNN C の理想的な組み合わせ	93
4.5	まとめ	94
	参考文献	98
5	推定精度改善手法の検討	101
5.1	はじめに	101
5.2	1° 近接波を検出する DNN を用いた組み合わせ	101
5.2.1	1° 近接波を検出する DNN の訓練	102
5.2.2	1° 近接波の検出結果に基づく DNN 選択	103
5.3	SNR を推定する DNN を用いた組み合わせ	107
5.3.1	訓練データの SNR と DNN パラメータ	107
5.3.2	推定精度の比較	109
5.3.3	SNR を推定する DNN の訓練	109
5.3.4	SNR の推定結果に基づく DNN 選択	114
5.4	まとめ	117
	参考文献	118
6	結論	119
	謝辞	121
	研究業績	123

1 序論

1.1 研究背景

電波の到来方向 (Direction Of Arrival, DOA) 推定は、車からの歩行者検知や遭難者の追跡、天文観測など、信号源または散乱体の位置を推定する様々なサービスで使われる技術である。2020 年春に提供が開始された第 5 世代移動通信システムでは、100 素子以上の送信アンテナを使う大規模 MIMO 技術が採用され、所望の方向にビームを向けてユーザ分離や SNR (Signal-to-Noise Ratio) の改善を図っている。このように、無線通信の分野でも到来方向推定は極めて重要な技術である。

ここ数十年で、到来方向推定にはアレーアンテナを使用するのが一般的となった。アレーアンテナを用いた到来方向推定法としては、メインローブを走査して受信電力が大きくなる方向を探す beamformer 法 [1] に始まり、それを発展させた Capon 法 (あるいは MVDR, Minimum Linear Distortionless Response) [2], 受信データ相関行列の固有値分解を利用した、部分空間法に基づく MUSIC (Multiple Signal Classification) [3], ESPRIT (Estimation of Signal Parameters via Rotational Invariance Techniques) [4] など多くの信号処理技術が研究されている [5]。特に、MUSIC と ESPRIT は、レイリー限界 [6] を超える高い推定精度をもつ手法として広く知られている。

計算資源が発展した近年では、圧縮センシングが到来方向推定の分野に適用されている [7]。圧縮センシングは信号処理やデータ圧縮などの分野で主に用いられる手法で、スパース性をもつ原信号を、その次元より少ない観測から復元するものである [8]。到来方向推定では、アンテナ周囲の角度領域を細かく分割すると到来波数はその分割数よりも十分に小さくなるため、圧縮センシングを適用することができる。

この方法で推定される到来方向は事前に決められた角度グリッドで量子化されることから、圧縮センシングを用いた到来方向推定法はオングリッド推定に分類される。つまり、到来方向を実数値で推定可能である MUSIC のような一般的なオフグリッド推定法と異なり、圧縮センシングを用いた到来方向推定では事前に決められたグリッド

ド間隔に依存する量子化誤差を避けられない。しかし、圧縮センシングにおいて解を求めるアルゴリズムの1つである **HQR (Half-Quadratic Regularization)** を用いた到来方向推定では、逆行列演算を繰り返し行う必要があるものの、マルチバンド信号を扱うことで **MUSIC** よりも高精度な推定が可能であることが報告されている [9]。このように量子化誤差を許容できる場合、他の新しいオングリッド推定法を適用することでより高精度な推定が実現できると期待される。

深層学習は、オングリッド推定に適したその典型的な手法である。これは、**Hinton** らの研究 [10, 11] を皮切りに画像、音声、言語などの分野で盛んに研究されるようになった、複数の層をもつ深いニューラルネットワーク (**Deep Neural Network, DNN**) を用いる機械学習の手法の1つである。基本的な順伝播型全結合ネットワークを用いた場合、訓練には多数の計算が必要となるものの、訓練済みのネットワークを用いて推定を行う際は行列とベクトルの乗算が主な計算となる。これは、**MUSIC** で要求される固有値分解や **HQR** で要求される反復逆行列計算より簡易である。また、ある特定の環境に特化した推定器を構築できる点も、**DNN** を用いた推定法の利点の1つである。従来法では推定が困難な条件に適した **DNN** を得られれば、従来法を超える精度で推定が可能となることも期待される。

到来方向推定の分野において深層学習は、マイクアレーを用いた音源位置推定に最初に適用された [12]。文献 [13] では、畳み込みニューラルネットワーク (**Convolutional Neural Network, CNN**) を使用して球面音波の到来方向推定を行っている。最近では、無線信号源の位置推定においても深層学習を用いた論文がいくつか報告されている [14–18]。文献 [14] では、合成開口円アレーによる到来方向推定において、**DNN** を用いて圧縮センシングの角度グリッドを決定することで推定精度の向上と計算時間の削減が可能であることを示している。文献 [15] では、大規模 **MIMO** において **DNN** で到来方向推定を行い、その結果をチャネル推定に用いている。文献 [16] で提案されている **DNN** は、空間フィルタリングを行う自己符号化器と、空間スペクトルを推定する全結合ネットワークを組み合わせることで高い推定精度を示している。文献 [17] では、円アレーを用いた大規模 **MIMO** において **DNN** を用いて到来方向推定を行い、

従来の最尤推定と同等かそれ以上の精度をより低い計算負荷で得られることを示している。文献 [18] では、到来方向推定を回帰問題として扱い、MIMO において複素 ResNet (Residual Network) を用いて到来方向推定を行っている。しかし、これらはアプリケーション指向の検討であり、アンテナが大規模である [15, 17, 18], (合成開口) 円アレーを用いている [14, 17], ビーム空間を分割している [16], 複素ニューラルネットワークを使用している [18] といった点は一般的ではない。

1.2 本論文の目的

本論文は、線形アレーアンテナに 2 波の狭帯域信号が到来する基本的な条件において、DNN の適用可能性を検討することを目的としている。

本論文では、まずオングリッド推定と相性のよい整数角度で信号が到来する条件で、DNN の適用方法の検討と基本的な性能評価を行う。DNN への入力として、アレーアンテナで受信した複素振幅を用いる方法が考えられる。しかし、この場合はスナップショット数に合わせて入力層が異なる DNN をいくつも用意する必要がある。そこで本論文では、MUSIC などでも用いられている受信データ相関行列を入力とする。この場合、スナップショットは受信データ相関行列の精度向上にのみ用いられるため、DNN の構造には影響しない。一般に到来波数は未知であるため、出力層では圧縮センシングと同様に角度グリッドを設け、そのグリッド上に信号があるかどうかを判定する。つまり、この出力は離散角度スペクトルを表している。このように設計した DNN を、SNR を種々のパターンで変化させた受信データを用いて訓練し、到来方向推定精度を評価する。加えて、一般に推定が困難とされる近接波の推定精度を評価するため、2 波の到来角度差が 1° である条件で訓練した DNN について検討する。さらに、これら 2 種の DNN を理想的に組み合わせたときの推定精度について検討する。

次に、整数角度で到来する条件を廃し、DNN の出力として設定した角度グリッドに拘束されない実数角度から到来する条件で推定精度の評価を行う。この場合、DNN の出力として設定した角度グリッドの境界上に信号が到来した場合に、境界を挟んで隣

り合う 2 つのユニットの出力が大きくなり、ときには最近傍ユニットの推定に失敗する問題がある。この問題を解決するため、角度グリッドの境界が重ならないように配置した 2 つの DNN を組み合わせて推定する手法を提案する。加えて、整数角度での検討と同様に、到来角度差が 1° である条件で訓練した DNN を理想的に組み合わせたときの推定精度について検討する。

最後に、具体的な組み合わせ手法の検討と推定精度の更なる向上のため、到来角度差が 1° であったかを検出する DNN を用いて、 1° 近接条件で訓練した DNN と、到来角度差の制約なしに訓練した DNN を切り替えて推定する手法、SNR を推定する DNN を用いて、異なる SNR で訓練した DNN を切り替えて推定する手法について検討する。

1.3 本論文の構成

図 1-1 に本論文の構成を示す。

第 1 章は序論である。研究の背景と目的について述べた。

第 2 章では、アレーアンテナの定式化と、これを用いた代表的な到来方向推定法である beamformer 法、Capon 法、MUSIC とその派生手法である Root-MUSIC について説明する。

第 3 章^{*1}では、整数角度における DNN の適用可能性について述べる。基本的な順伝播型全結合ネットワークの定式化を行い、誤差逆伝播法に基づく勾配降下法によるネットワークの訓練について説明する。アレーアンテナから得られる受信データ相関行列を入力し、離散角度スペクトルが出力されるような DNN を設計する。訓練データの SNR を種々のパターンで変化させた場合の学習曲線を示し、得られた DNN と Root-MUSIC の推定精度を比較する。加えて、一般に推定が困難とされる近接波の推定精度を評価するため、2 波の到来角度差が 1° である条件で訓練した DNN について検討する。さらに、ここまでで得られた、到来角度差の制約あり、またはなしに訓練

*1 第 3 章は、IEICE Trans. Commun. に掲載された同著者の論文“Fundamental Trial on DOA Estimation with Deep Learning” [19] に基づく。

した2つのDNNを理想的に組み合わせた場合について考察する。

第4章^{*2}では、実数角度におけるDNNの適用可能性について述べる。DNNの中間層とユニット数を変化させて訓練を行い、推定精度を評価する。DNNの角度グリッドの境界上に信号が到来した場合に隣接ユニットへ誤る問題について述べ、グリッド境界が重ならないよう配置した2つのDNNを組み合わせることでこの問題を解決する手法を提案する。加えて、到来角度差が 1° である条件でDNNを訓練し、上記提案手法を適用した場合や、到来角度差の制約なしに訓練したDNNと理想的に組み合わせた場合の推定精度について検討する。

第5章では、推定精度の更なる向上のため、異なる条件で訓練した複数のDNNを組み合わせる手法について検討する。初めに、 1° 近接波を検出するDNNを構築し、 1° 近接条件で訓練したDNNと、到来角度差の制約なしに訓練したDNNを切り替えて推定する手法を提案する^{*3}。次に、SNRを推定するDNNを構築し、異なるSNRで訓練したDNNを切り替えて推定する手法を提案する。

第6章は結論である。本論文の内容と得られた成果を総括する。

^{*2} 第4章は、IEICE Trans. Commun. に掲載予定（早期公開中）の同著者の論文“Accuracy Improvement in DOA Estimation with Deep Learning” [20] に基づく。

^{*3} 第5章の一部は、IEICE Trans. Commun. に掲載予定（早期公開中）の同著者の論文“Accuracy Improvement in DOA Estimation with Deep Learning” [20] に基づく。

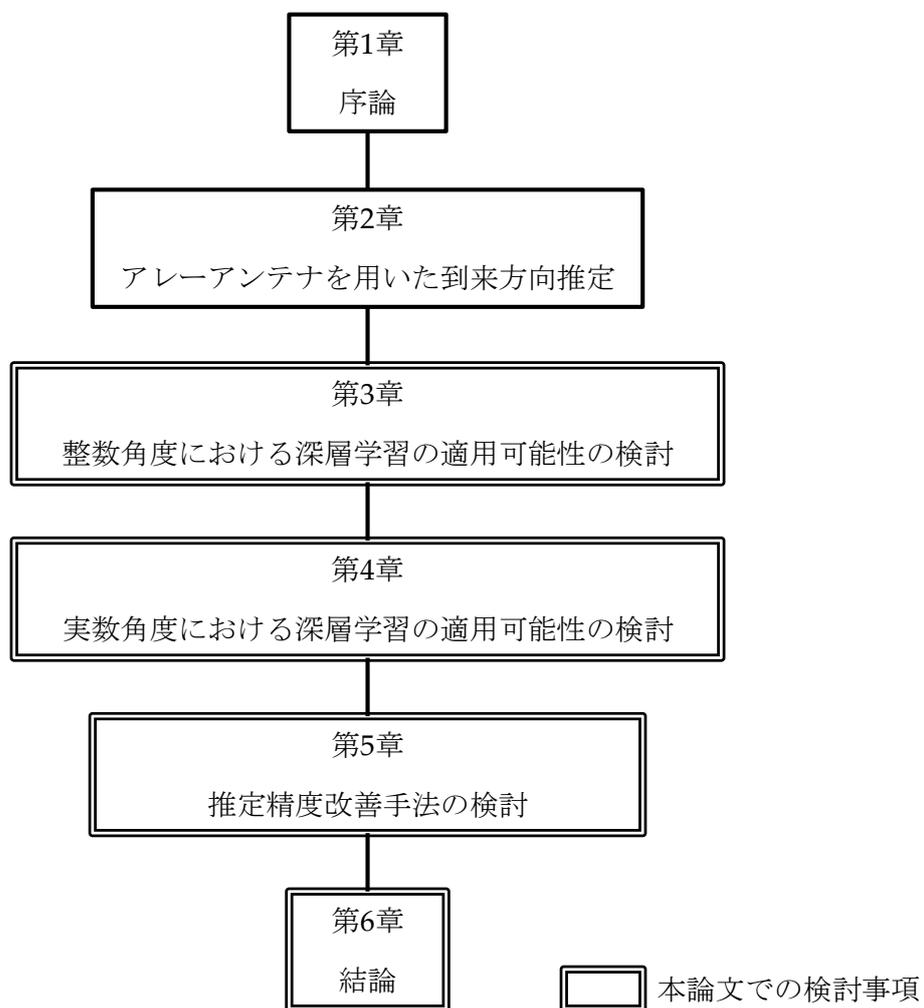


図 1-1 本論文の構成

参考文献

-
- [1] D. D. Van Veen and K. M. Buckley, “Beamforming: A versatile approach to spatial filtering,” *IEEE ASSP Mag.*, vol. 5, no. 2, pp. 4–24, Apr. 1988, DOI:10.1109/53.665.
- [2] J. Capon, “High resolution frequency-wavenumber spectrum analysis,” *Proc. IEEE*, vol. 57, no. 8, pp. 1408–1418, Aug. 1969, DOI:10.1109/PROC.1969.7278.
- [3] R. O. Schmidt, “Multiple emitter location and signal parameter estimation,” *IEEE Trans. Antennas Propag.*, vol. AP-34, No. 3, pp. 276–280, Mar. 1986, DOI:10.1109/TAP.1986.1143830.
- [4] R. Roy and T. Kailath, “ESPRIT — estimation of signal parameters via rotational invariance techniques,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 37, no. 7, pp. 984–995, July 1989, DOI:10.1109/29.32276.
- [5] 菊間信良, “アレーアンテナによる適応信号処理,” 科学技術出版, 東京, 1998.
- [6] 久保田広, “波動光学,” 岩波書店, 東京, 1971.
- [7] A. Massa, P. Rocca, and G. Oliveri, “Compressive sensing in electromagnetics — a review,” *IEEE Antennas Propag. Mag.*, vol. 57, no. 1, pp. 224–238, Feb. 2015, DOI:10.1109/MAP.2015.2397092.
- [8] K. Hayashi, M. Nagahara, and T. Tanaka, “A user’s guide to compressed sensing for communications systems,” *IEICE Trans. Commun.*, vol. E96-B, no. 3, pp. 685–712, Mar. 2013, DOI:10.1587/transcom.E96.B.685.
- [9] T. Terada, T. Nishimura, Y. Ogawa, T. Ohgane, and H. Yamada, “DOA estimation for multi-band signal sources using compressed sensing techniques with Khatri-Rao processing,” *IEICE Trans. Commun.*, vol. E97-B, no. 10, pp. 2110–2117, Oct. 2014, DOI:10.1587/transcom.E97.B.2110.
- [10] G. E. Hinton, S. Osindero, and Y. Teh, “A fast learning algorithm for deep belief nets,” *Neural Computation*, vol. 18, no. 7, pp. 1527–1544, July 2006,
-

- DOI:10.1162/neco.2006.18.7.1527.
- [11] G. E. Hinton and R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol. 313, no. 5786, pp. 504–507, July 2006, DOI:10.1126/science.1127647.
- [12] R. Takeda and K. Komatani, “Sound source localization based on deep neural networks with directional activate function exploiting phase information,” *Proc. IEEE ICASSP 2016*, pp. 405–409, Mar. 2016, DOI:10.1109/icassp.2016.7471706.
- [13] W. Liu, J. Xin, W. Zuo, J. Li, N. Zheng and A. Sano, “Deep learning based localization of near-field sources with exact spherical wavefront model,” *Proc. Eur. Signal Process. Conf. (EUSIPCO)*, pp. 1–5, Sept. 2019, DOI:10.23919/EUSIPCO.2019.8903003.
- [14] 池田友典, 藤元美俊, 豊見本和馬, 山口良, “圧縮センシング・機械学習を併用した合成開口測定による到来方向推定,” 電子情報通信学会論文誌 B, Vol. J104-B, no. 11, pp. 872–879, Nov. 2021, DOI:10.14923/transcomj.2021APP0001.
- [15] H. Huang, J. Yang, H. Huang, Y. Song, and G. Gui, “Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system,” *IEEE Trans. Veh. Technol.*, vol. 67, no. 9, pp. 8549–8560, Sept. 2018, DOI:10.1109/TVT.2018.2851783.
- [16] Z. Liu, C. Zhang, and P. S. Yu, “Direction-of-arrival estimation based on deep neural networks with robustness to array imperfections,” *IEEE Trans. Antennas Propag.*, vol. 66, no. 12, pp. 7315–7327, Dec. 2018, DOI:10.1109/TAP.2018.2874430.
- [17] D. Hu, Y. Zhang, L. He and J. Wu, “Low-complexity deep-learning-based DOA estimation for hybrid massive MIMO systems with uniform circular arrays,” *IEEE Wirel. Commun. Lett.*, vol. 9, no. 1, pp. 83–86, Jan. 2020, DOI:10.1109/LWC.2019.2942595.
- [18] Y. Cao, T. Lv, Z. Lin, P. Huang and F. Lin, “Complex ResNet aided DoA estimation for near-field MIMO systems,” *IEEE Trans. Veh. Technol.*, vol. 69, no. 10,

-
- pp. 11139–11151, Oct. 2020, DOI:10.1109/TVT.2020.3007894.
- [19] Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, D. Kitayama, Y. Kishiyama, “Fundamental Trial on DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E103-B, no. 10, pp. 1127–1135, Oct. 2020, DOI:10.1587/transcom.2019EBP3260.
- [20] Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, T. Sato, Y. Kishiyama, “Accuracy Improvement in DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E105-B, no. 5, May 2022 (Advance publication), DOI:10.1587/transcom.2021EBT0001.

2 アレーアンテナを用いた到来方向推定

2.1 はじめに

素朴な到来方向推定法としては、指向性アンテナを物理的に回転させて受信電力が大きくなる方向を探す方法もあるが、近年ではアレーアンテナを用いた手法が主流である。アレーアンテナを用いた到来方向推定法として最も基本的な手法は、メインローブを走査して受信電力が大きくなる方向を探す **beamformer** 法 [1] である。**beamformer** 法には、メインローブを向けていない他の信号をサイドローブで受信した場合に推定精度が大きく劣化するという問題がある。そこで、ある方向にメインローブを向けると同時に、他の方向からの受信電力を最小化することでこの問題を解決した手法が **Capon** 法 [2] である。しかし、これらの手法ではメインローブを到来波に向けているため、複数の信号がメインローブの幅より近接して到来した場合にそれらを分離することは困難となる。

一方で、受信データ相関行列の固有空間が、互いに直交補空間である信号部分空間と雑音部分空間に分割できることを利用した最初の手法が **Pisarenko** 法 [3] である。この手法は時系列データを用いた推定法として提案されたものであるため、アレーアンテナでは実現が難しい、素子数が到来波より 1 だけ多いという仮定を利用している [4]。この条件を緩和し、さらに高精度な推定を実現したのが最小ノルム法 [5] や **MUSIC** (**M**ultiple **S**ignal **C**lassification) [6], **ESPRIT** (**E**stimation of **S**ignal **P**arameters via **R**otational **I**nvariance **T**echniques) [7] などの手法である。これらの手法は、ヌル走査により到来方向を推定する。一般にアレーアンテナのビームパターンに見られるヌルはメインローブよりもはるかに鋭いため、レイリー限界 [8] を超える角度分解能を実現できる。**Root-MUSIC** や **Unitary ESPRIT** などの手法 [9–13] は、**MUSIC**, **ESPRIT** を発展させた手法である。

本章では、アレーアンテナの受信信号を定式化し、**beamformer** 法と **Capon** 法について説明した後、受信データ相関行列の固有構造に見られる特徴と、それを利用

した代表的な到来方向推定法である MUSIC, Root-MUSIC について説明する. 最後に, ある条件下で到来方向推定を行った場合に達成可能な推定誤差の下限である CRB (Cramér-Rao Bound) [14, 15] について説明する.

2.2 アレーアンテナの受信データ相関行列

図 2-1 に示すように, 同一のアンテナからなる間隔 d の L 素子等間隔線形アレーアンテナに搬送波周波数 f , 波長 λ の K 個の平面波 $s_k(t)$ が角度 θ_k から到来したときを考える. このとき, 各素子が到来波を受信する時刻には θ_k に依存した差が生じる. 1 番目のアンテナを基準としたとき, l 番目のアンテナとの到来波の行路差 \mathbf{v}_k は

$$\mathbf{v}_k = (l-1)d \sin \theta_k \quad (k = 1, 2, \dots, K, l = 1, 2, \dots, L) \quad (2-1)$$

であるから, この行路差による到来時間差 t'_l は, 光速を c とすると

$$t'_l = \frac{\mathbf{v}_k}{c} = \frac{(l-1)d \sin \theta_k}{f\lambda} \quad (2-2)$$

となる.

l 番目のアンテナが k 番目の平面波を受信したときの信号は

$$\begin{aligned} x_{l,k}(t) &= s_k(t - t'_l) e^{2\pi f(t-t'_l)} \\ &= s_k(t - t'_l) e^{2\pi f t} e^{2\pi f \frac{(l-1)d \sin \theta_k}{f\lambda}} \\ &= s_k(t - t'_l) e^{2\pi f t} e^{-j \frac{2\pi}{\lambda} (l-1)d \sin \theta_k} \end{aligned} \quad (2-3)$$

で表せる. $s_k(t)$ の変動に対して t'_l が十分に小さいとき, $s_k(t - t'_l) \approx s_k(t)$ と近似できるので

$$x_{l,k}(t) = s_k(t) e^{2\pi f t} e^{-j \frac{2\pi}{\lambda} (l-1)d \sin \theta_k} \quad (2-4)$$

となる. この信号は, 等価低域系で表すと

$$x_{l,k}(t) = s_k(t) e^{-j \frac{2\pi}{\lambda} (l-1)d \sin \theta_k} \quad (2-5)$$

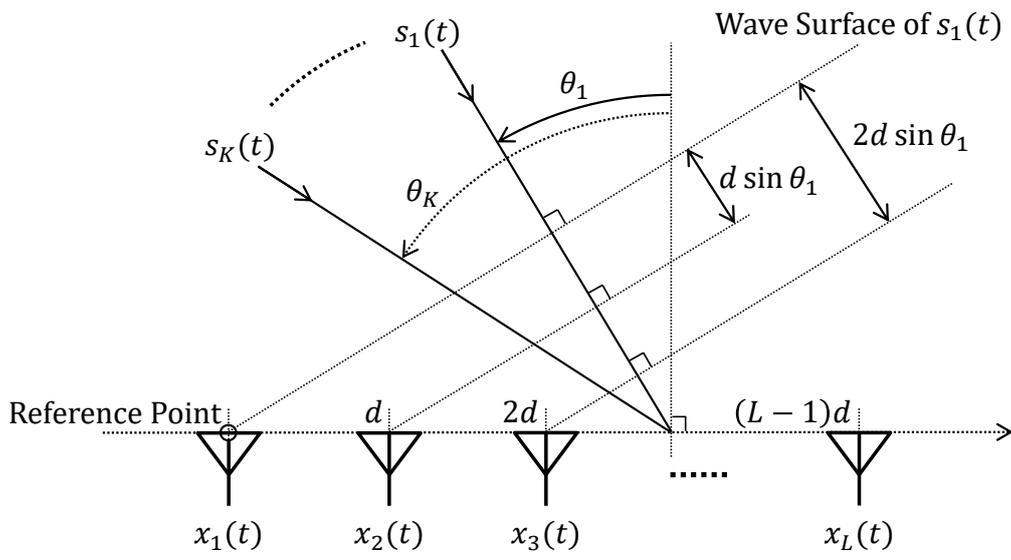


図 2-1 L 素子等間隔線形アレーアンテナと到来波 (©2020 IEICE, [16] Fig. 1)

である．よって，アンテナの付加雑音を $n_l(t)$ で表すと， l 番目のアンテナの受信データは

$$x_l(t) = \sum_{k=1}^K s_k(t) e^{-j \frac{2\pi}{\lambda} (l-1) d \sin \theta_k} + n_l(t) \quad (2-6)$$

である．

このアレーアンテナ全体の受信データをベクトル形式でまとめると以下のようになる．

$$\begin{aligned} \mathbf{x}(t) &= \begin{bmatrix} x_1(t) & x_2(t) & \cdots & x_L(t) \end{bmatrix}^T \\ &= \mathbf{A} \mathbf{s}(t) + \mathbf{n}(t) \end{aligned} \quad (2-7)$$

ここで，

$$\mathbf{A} = \begin{bmatrix} \mathbf{a}(\theta_1) & \mathbf{a}(\theta_2) & \cdots & \mathbf{a}(\theta_K) \end{bmatrix} \quad (2-8)$$

$$= \begin{bmatrix} 1 & 1 & \cdots & 1 \\ e^{-j \frac{2\pi}{\lambda} d \sin \theta_1} & e^{-j \frac{2\pi}{\lambda} d \sin \theta_2} & \cdots & e^{-j \frac{2\pi}{\lambda} d \sin \theta_K} \\ \vdots & \vdots & & \vdots \\ e^{-j \frac{2\pi}{\lambda} (L-1) d \sin \theta_1} & e^{-j \frac{2\pi}{\lambda} (L-1) d \sin \theta_2} & \cdots & e^{-j \frac{2\pi}{\lambda} (L-1) d \sin \theta_K} \end{bmatrix} \quad (2-9)$$

$$\mathbf{s}(t) = \begin{bmatrix} s_1(t) & s_2(t) & \cdots & s_K(t) \end{bmatrix}^T \quad (2-10)$$

$$\mathbf{n}(t) = \begin{bmatrix} n_1(t) & n_2(t) & \cdots & n_L(t) \end{bmatrix}^T \quad (2-11)$$

である．このときの L 次元列ベクトル $\mathbf{a}(\theta)$ をモードベクトル， K 個のモードベクトルを列とする $L \times K$ 行列 \mathbf{A} をモード行列という．以降，モードベクトル，受信データベクトルは式 (2-7) に基づくとする．

受信データ相関行列は受信データベクトルを用いて以下のように定義される L 次正方行列である．

$$\mathbf{R}_{xx} = E[\mathbf{x}(t) \mathbf{x}^H(t)] = \mathbf{A} \mathbf{S} \mathbf{A}^H + \mathbf{R}_N \quad (2-12)$$

$E[\cdot]$ はアンサンブル平均， $[\cdot]^H$ は行列の共役転置（随伴行列）を表している．このときの行列 \mathbf{S} を信号相関行列といい，対角成分に K 個の信号電力をもつ K 次正方行列と

なる。

$$\mathbf{S} = E[\mathbf{s}(t)\mathbf{s}^H(t)] = \begin{bmatrix} |s_1(t)|^2 & & & * \\ & |s_2(t)|^2 & & \\ & & \ddots & \\ * & & & |s_K(t)|^2 \end{bmatrix} \quad (2-13)$$

非対角成分は到来波間の相関係数を含む要素である。すべての到来波が無相関のとき非対角成分は 0 になり、 \mathbf{S} は対角行列となる。また、 L 次正方行列 \mathbf{R}_N は雑音相関行列といい、付加雑音を平均 0、分散（電力） σ^2 のホワイトノイズと仮定するとき、

$$\mathbf{R}_N = E[\mathbf{n}(t)\mathbf{n}^H(t)] = \sigma^2 \mathbf{I} \quad (2-14)$$

である。ただし、 \mathbf{I} は単位行列である。よって、式 (2-12) は

$$\mathbf{R}_{xx} = \mathbf{A}\mathbf{S}\mathbf{A}^H + \sigma^2 \mathbf{I} \quad (2-15)$$

となる。この受信データ相関行列はエルミート行列である。以降、受信データ相関行列は式 (2-15) で表せると仮定する。実際、アンテナの付加雑音は多くの場合、熱雑音とみなせるため、ホワイトノイズでモデル化することは妥当である。

2.3 メインローブ走査による到来方向推定

2.3.1 beamformer 法

図 2-2 に示すように、アレーアンテナの受信信号を同相で足し合わせるとき、そのビームパターンは式 (2-5) から

$$P_0(\theta_k) = |s_k(t)|^2 \left| \sum_{l=1}^L e^{-j\frac{2\pi}{\lambda}(l-1)d\sin\theta_k} \right|^2 \quad (2-16)$$

となる。したがって、位相調整を行わない場合、アレーアンテナのメインローブは 0° を向いており、正面方向からの信号を最も強く受信する。図 2-3 は、式 (2-16) のビームパターンを $\theta_k = -90^\circ$ から 90° の範囲で示したものである。

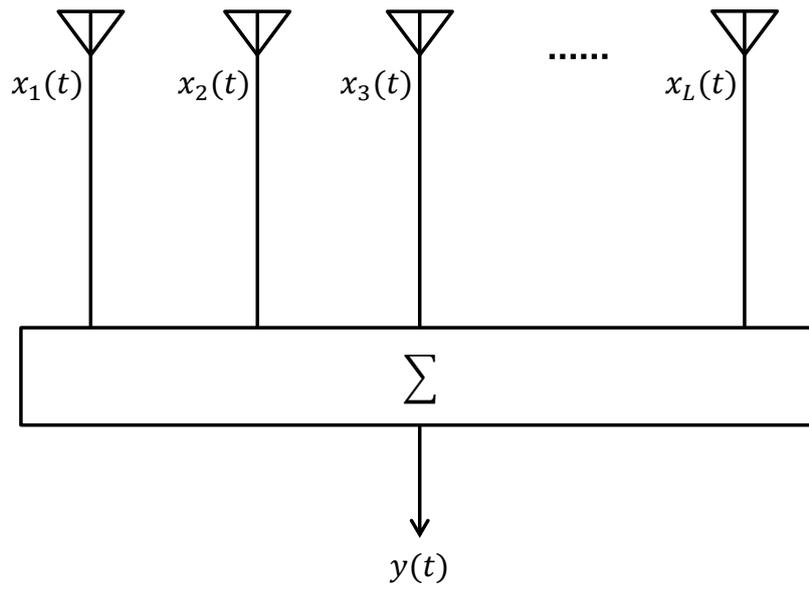


図 2-2 アレーアンテナの受信信号の同相合成

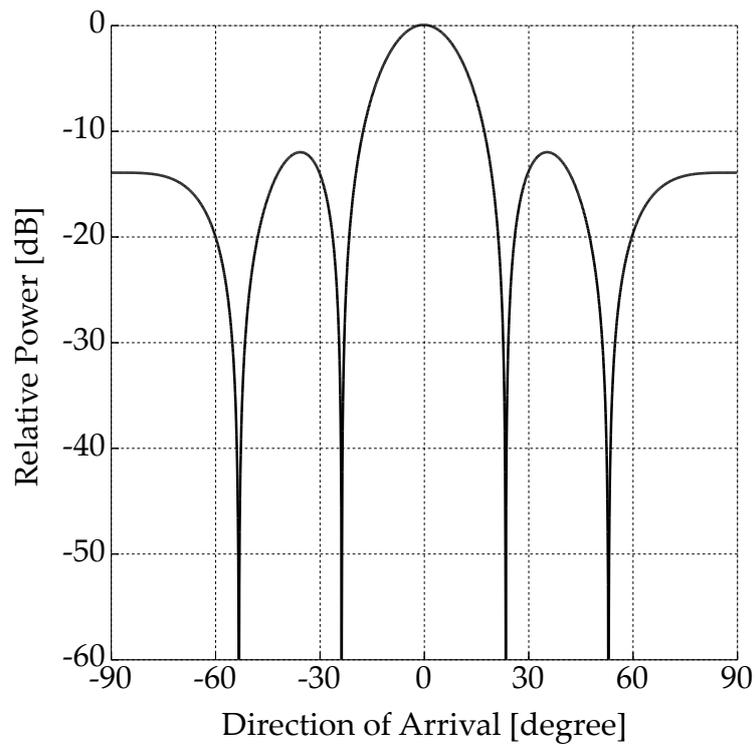


図 2-3 同相合成時のアレーアンテナのビームパターン

次に、図 2-4 に示すように、各素子にウェイト w_l を掛けてメインローブを任意の方向 θ に平行移動させることを考える。アレーアンテナの受信信号の総和 $y(t)$ を、ウェイトベクトル

$$\mathbf{w} = [w_1 \quad w_2 \quad \cdots \quad w_L]^T \quad (2-17)$$

を用いて

$$y(t) = \mathbf{w}^H \mathbf{x}(t) = s_k(t) \mathbf{w}^H \mathbf{a}(\theta_k) \quad (2-18)$$

と表すことにすると、

$$\begin{aligned} P(\theta_k) &= |s_k(t)|^2 \left| \sum_{l=1}^L e^{-j \frac{2\pi}{\lambda} (l-1) d \sin(\theta_k - \theta)} \right|^2 \\ &= |s_k(t)|^2 \left| \sum_{l=1}^L e^{j \frac{2\pi}{\lambda} (l-1) d \sin \theta} e^{-j \frac{2\pi}{\lambda} (l-1) d \sin \theta_k} \right|^2 \end{aligned} \quad (2-19)$$

より、 w_l を

$$w_l = e^{-j \frac{2\pi}{\lambda} (l-1) d \sin \theta} \quad (2-20)$$

のように設定すれば、メインローブを θ 方向に向けられることがわかる。図 2-5 は、 $\theta = 30^\circ$ としたときのビームパターンである。このように角度 θ を全方位にわたって走査し、受信電力が大きくなる方向を探す手法が beamformer 法 [1] である。

θ の関数とみなしたウェイトベクトル \mathbf{w} はモードベクトルと一致する。このときのアレーアンテナの受信電力は

$$\begin{aligned} P_{\text{out}} &= \frac{1}{2} E[|y(t)|^2] = \frac{1}{2} \mathbf{w}^H \mathbf{R}_{xx} \mathbf{w} \\ &= \frac{1}{2} \mathbf{a}^H(\theta) \mathbf{R}_{xx} \mathbf{a}(\theta) \end{aligned} \quad (2-21)$$

である。beamformer 法では、式 (2-21) を正規化した角度スペクトル

$$P_{\text{beamformer}}(\theta) = \frac{P_{\text{out}}}{\frac{1}{2} \mathbf{a}^H(\theta) \mathbf{a}(\theta)} = \frac{\mathbf{a}^H(\theta) \mathbf{R}_{xx} \mathbf{a}(\theta)}{\mathbf{a}^H(\theta) \mathbf{a}(\theta)} \quad (2-22)$$

に生じるピークを探すことで到来方向を推定する [17].

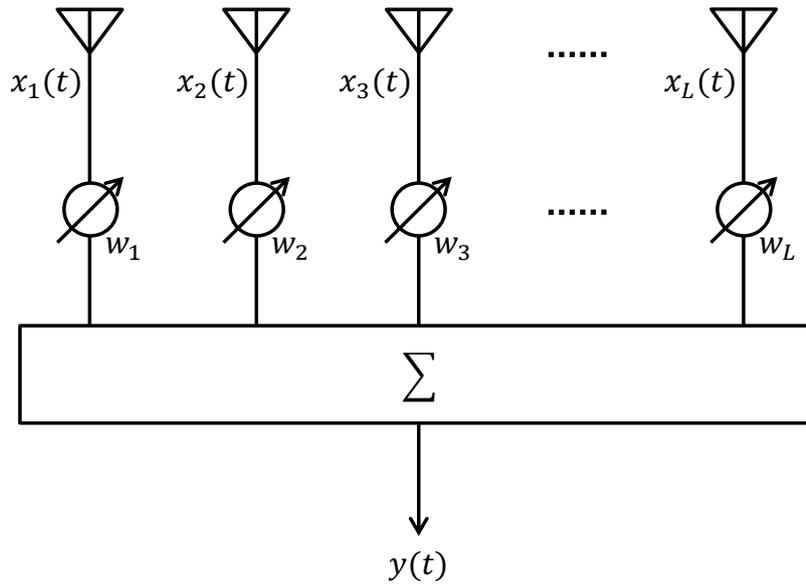


図 2-4 アレーアンテナの受信信号の荷重合成

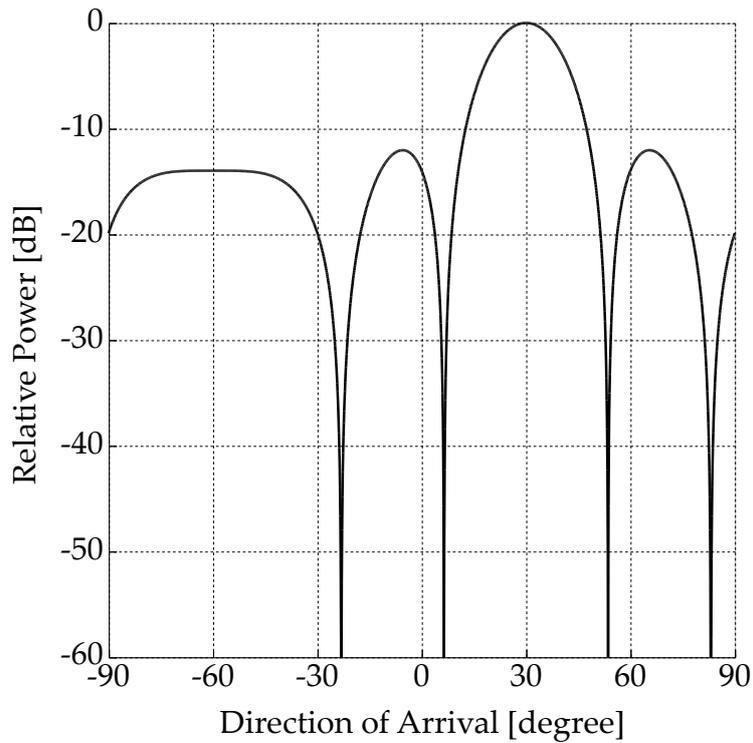


図 2-5 荷重合成時のアレーアンテナのビームパターン ($\theta = 30^\circ$)

図 2-6 は、5 素子半波長等間隔線形アレーアンテナに等電力、無相関な狭帯域信号 2 波が良好な SNR で 0° と 30° から到来したときの beamformer スペクトルの一例である。 0° と 30° 近辺に緩やかなピークが生じている。このスペクトルは、式 (2-19) において $\theta = 0^\circ, 30^\circ$ としたときのビームパターンの総和、すなわち図 2-3、2-5 のビームパターンの総和とほぼ等しい。したがって、beamformer 法ではメインローブの幅よりも近接した到来波を分離することはできない。図 2-7 は、図 2-6 と同じ条件の 2 波が 0° と 20° から到来したときの beamformer スペクトルの一例である。 0° から 20° 近辺に 1 つの大きなピークが生じており、2 波が分離できていないことがわかる。

2.3.2 Capon 法

beamformer 法ではメインローブのみを制御しているため、複数の信号が到来した場合に、メインローブを向けていない他の信号をサイドローブで受信してしまうという問題がある。そこで、ある方向にメインローブを向けると同時に、他の方向からの受信電力を最小化するようなウェイトを用いてメインローブを走査する手法が Capon 法 [2] である。すなわち、

$$\arg \min_{\mathbf{w}} \left(P_{\text{out}} = \frac{1}{2} \mathbf{w}^H \mathbf{R}_{xx} \mathbf{w} \right) \quad \text{subject to} \quad \mathbf{w}^H \mathbf{a}(\theta) = 1 \quad (2-23)$$

を満たす \mathbf{w} である。この解は、DCMP (Directionally Constrained Minimization of Power, 方向拘束付電力最小化) アダプティブアレーアンテナ [18, 19] における最適ウェイトと同様に Lagrange の未定係数法を用いて求めることができ、

$$\mathbf{w} = \frac{\mathbf{R}_{xx}^{-1} \mathbf{a}(\theta)}{\mathbf{a}^H(\theta) \mathbf{R}_{xx}^{-1} \mathbf{a}(\theta)} \quad (2-24)$$

である。また、このときのアレーアンテナの受信電力は

$$P_{\text{out}} = \frac{1}{2} \mathbf{w}^H \mathbf{R}_{xx} \mathbf{w} = \frac{1}{2 \mathbf{a}^H(\theta) \mathbf{R}_{xx}^{-1} \mathbf{a}(\theta)} \quad (2-25)$$

となる。ただし、式 (2-25) の定数倍は到来方向推定の特性に影響しないので、Capon 法では、式 (2-25) から定係数を取り除いた角度スペクトル

$$P_{\text{Capon}}(\theta) = 2P_{\text{out}} = \frac{1}{\mathbf{a}^H(\theta) \mathbf{R}_{xx}^{-1} \mathbf{a}(\theta)} \quad (2-26)$$

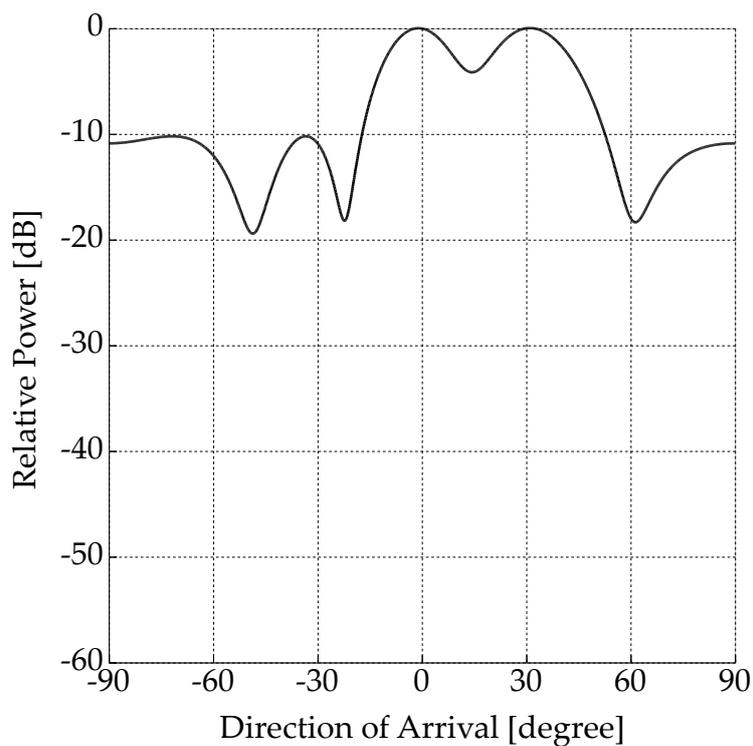


図 2-6 beamformer スペクトル (アンテナ素子数 : 5, 到来波 : 0°, 30°)

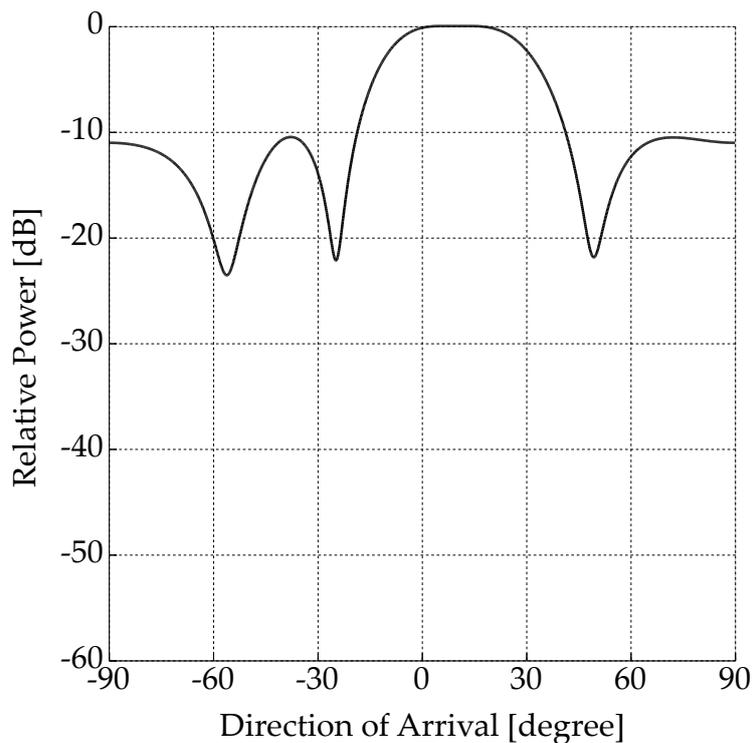


図 2-7 beamformer スペクトル (アンテナ素子数 : 5, 到来波 : 0°, 20°)

に生じるピークを探すことで到来方向を推定する [17].

図 2-8 は, 図 2-6 と同じ条件で 2 波が 0° と 30° から到来したときの Capon スペクトルの一例である. 図 2-6 と比較してピークが鋭くなっており, サイドローブの影響が低減されていることがわかる. 図 2-9 は, 2 波が 0° と 20° から到来したときの Capon スペクトルの一例である. 図 2-7 の beamformer 法では分離できていなかった 2 波を検出できており, 推定精度が改善していることがわかる.

2.4 受信データ相関行列の固有構造

式 (2-15) の受信データ相関行列はエルミート行列であるから,

$$\mathbf{R}_{xx}\mathbf{e}_l = \lambda_l\mathbf{e}_l \quad (2-27)$$

から得られる固有ベクトル \mathbf{e}_l , 対応する固有値 λ_l を用いて

$$\mathbf{R}_{xx} = \sum_{l=1}^L \lambda_l \mathbf{e}_l \mathbf{e}_l^H = \mathbf{E}\mathbf{\Lambda}\mathbf{E}^H \quad (2-28)$$

と書ける. ここで, \mathbf{E} は L 個の固有ベクトルを列とする L 次正方行列, $\mathbf{\Lambda}$ は L 個の固有値を対角成分とする L 次対角行列である.

$$\mathbf{E} = [\mathbf{e}_1 \quad \mathbf{e}_2 \quad \cdots \quad \mathbf{e}_L] \quad (2-29)$$

$$\mathbf{\Lambda} = \text{diag}[\lambda_1 \quad \lambda_2 \quad \cdots \quad \lambda_L] \quad (2-30)$$

ただし, 固有値は λ_1 が最も大きく, 順に $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_L$ となっているものとする.

ここで, 式 (2-27) に式 (2-15) を代入して

$$\mathbf{A}\mathbf{S}\mathbf{A}^H\mathbf{e}_l = (\lambda_l - \sigma^2)\mathbf{I}\mathbf{e}_l = \lambda'_l\mathbf{e}_l \quad (\lambda'_l := \lambda_l - \sigma^2) \quad (2-31)$$

と整理する. $\mathbf{A}\mathbf{S}\mathbf{A}^H$ は L 次正方行列であるが, ランクは到来波数分しかない. したがって, その固有値 λ'_l は $K+1$ 番目以降 0 である.

$$\lambda'_1 \geq \lambda'_2 \geq \cdots \geq \lambda'_K > \lambda'_{K+1} = \cdots = \lambda'_L = 0 \quad (2-32)$$

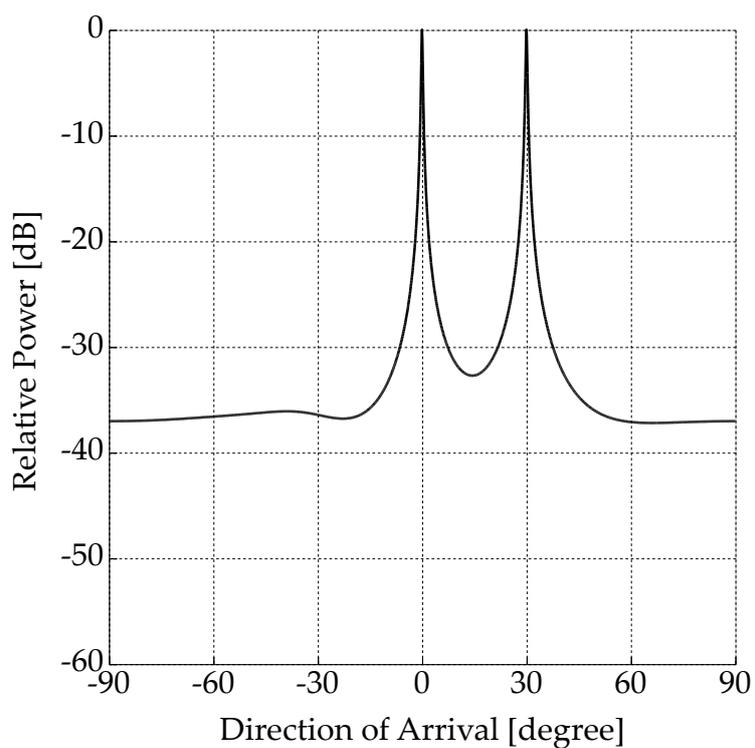


図 2-8 Capon スペクトル (アンテナ素子数 : 5, 到来波 : $0^\circ, 30^\circ$)

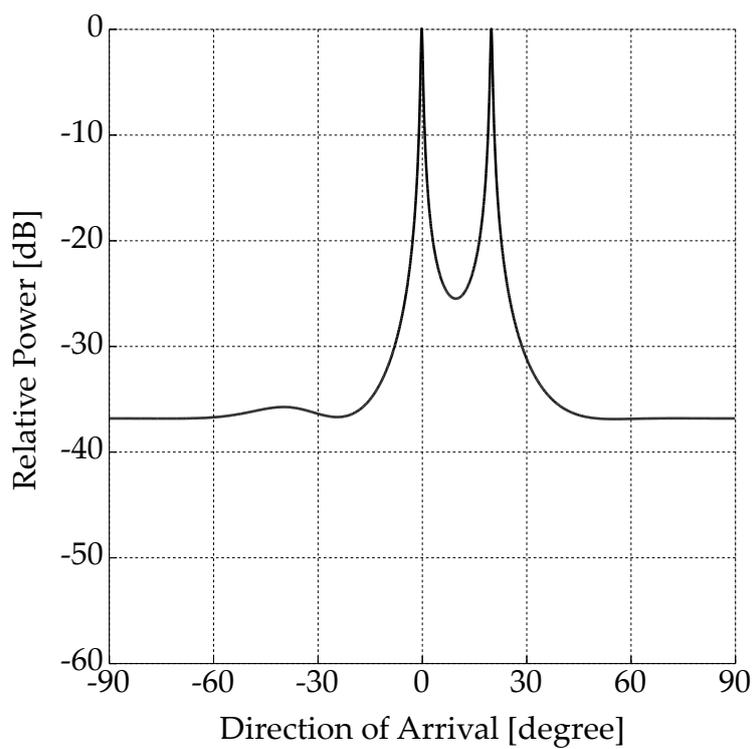


図 2-9 Capon スペクトル (アンテナ素子数 : 5, 到来波 : $0^\circ, 20^\circ$)

式 (2-31) と式 (2-32) から、受信データ相関行列の固有値は以下のように分布することがわかる。

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_K > \lambda_{K+1} = \dots = \lambda_L = \sigma^2 \quad (2-33)$$

このように、受信データ相関行列の固有値分布は雑音電力と等しい $L-K$ 個の雑音固有値と、それらより大きい K 個の信号固有値に分割できる。この性質を用いることで、到来波数 K と雑音電力 σ^2 が推定できる。ただし、実際の到来方向推定では、ある時間間隔ごとにアンテナからデータを取得するスナップショットを用いて受信データ相関行列を得るため、有限性に起因する誤差によって固有値分布から到来波数を推定することが困難となる場合がある。到来波数推定を行う手法も数多く提案されており、代表的なものとしては AIC (Akaike Information Criteria) [20], MDL (Minimum Description Length) [21] などがある。以降では、到来波数は正確に推定できたとする。

式 (2-32) から、 $l = K+1, K+2, \dots, L$ の範囲において式 (2-31) は

$$\mathbf{A}\mathbf{S}\mathbf{A}^H \mathbf{e}_l = \lambda'_l \mathbf{e}_l = \mathbf{0} \quad (2-34)$$

である。 \mathbf{S} には逆行列が存在する。 \mathbf{A} は正方行列ではないがフルランクであるため、その随伴行列を掛けることで逆行列をもたせることができる。 $(\mathbf{A}^H \mathbf{A}\mathbf{S})^{-1}$ を左から掛けることにより

$$\mathbf{A}^H \mathbf{e}_l = \mathbf{0} \quad (2-35)$$

$$\mathbf{a}^H(\theta_k) \mathbf{e}_l = 0 \quad (k = 1, 2, \dots, K) \quad (2-36)$$

が得られる。これは、雑音固有値に対応する雑音固有ベクトルは到来波すべてのモードベクトルと直交することを表している。また、式 (2-36) をエルミート転置することで

$$\mathbf{e}_l^H \mathbf{a}(\theta_k) = 0 \quad (2-37)$$

が得られる。式 (2-18) と比較すると、雑音固有ベクトルは到来波すべてにヌルを向けるウェイトであることがわかる。したがって、 $L-K$ 個の雑音固有ベクトルをウェィ

トとするマルチビームアレーアンテナのビームパターンに生じるヌルを探すことで到来方向が推定できる。図 2-3, 2-5 に見られるように、一般に、ビームパターンのヌルはメインローブよりはるかに鋭いため、ヌル走査に基づく到来方向推定ではレイリー限界 [8] を超える角度分解能を実現できる。

2.5 MUSIC による到来方向推定

2.5.1 Spectral-MUSIC

雑音固有ベクトルをウェイトとして用いたときのビームパターンを反転すると $L-K$ 個の角度スペクトルが得られる。

$$P_{\text{MUSIC}}^l(\theta) = \frac{1}{|\mathbf{e}_l^H \mathbf{a}(\theta)|^2} \quad (l = K+1, K+2, \dots, L) \quad (2-38)$$

これらのスペクトルは共通して $\theta = \theta_k$ ($k = 1, 2, \dots, K$) で発散し、ピークを生ずるが、それ以外の角度においても各々スプリアスピークが生じる可能性がある。この余分なピークを抑圧し、共通の真の到来方向のみを取り出すため、調和平均に基づく平均化処理を導入する。

$$P_{\text{MUSIC}}(\theta) = \frac{1}{\sum_{l=K+1}^L \frac{1}{P_{\text{MUSIC}}^l(\theta)}} \quad (2-39)$$

式 (2-39) を整理して正規化した角度スペクトル

$$P_{\text{MUSIC}}(\theta) = \frac{\mathbf{a}^H(\theta) \mathbf{a}(\theta)}{\sum_{l=K+1}^L |\mathbf{e}_l^H \mathbf{a}(\theta)|^2} = \frac{\mathbf{a}^H(\theta) \mathbf{a}(\theta)}{\mathbf{a}^H(\theta) \mathbf{E}_N \mathbf{E}_N^H \mathbf{a}(\theta)} \quad (2-40)$$

に生じるピークを探すことで到来方向を推定する手法を Spectral-MUSIC [6] という。ここで、 \mathbf{E}_N は $L-K$ 個の雑音固有ベクトルを列とする $L \times (L-K)$ 行列である。単に MUSIC といった場合はこの Spectral-MUSIC を指すことが多い。

以上のように、受信データ相関行列 \mathbf{R}_{xx} の固有値分布から到来波数 K と雑音電力 σ^2 が、MUSIC スペクトルから到来方向 θ_k が推定されれば、式 (2-15) を信号相関行

列 \mathbf{S} について解くことで到来波の電力と相関を求めることもできる。

$$\mathbf{S} = (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H (\mathbf{R}_{xx} - \sigma^2 \mathbf{I}) \mathbf{A} (\mathbf{A}^H \mathbf{A})^{-1} \quad (2-41)$$

ただし、この計算は受信データ相関行列を各到来方向成分に分解する操作であるため、複数波が近接して到来した場合に到来方向推定誤差が電力推定誤差に大きく影響する点に注意が必要である。

また、複数の到来波が互いに完全相関であった場合、それらの合成波はあたかも 1 波のように振る舞いながらアンテナに入射する。このような環境では、信号部分空間が縮退して受信データ相関行列のランクが本来の到来波数未満となるため、固有構造に基づいた到来方向推定法は正しく動作しない。このような場合には、SSP (Spatial Smoothing Preprocessing, 空間平均法) [22], MSSP (Modified SSP) [23], FBSSP (Forward/Backward SSP) [24] などの相関抑圧前処理法を適用して信号相関行列のランクを回復させてから固有構造解析を行うとよい。

図 2-10 は、図 2-6, 2-8 と同じ条件で 2 波が 0° と 30° から到来したときの MUSIC スペクトルの一例である。また、図 2-11 は、2 波が 0° と 20° から到来したときの MUSIC スペクトルの一例である。どちらの場合においても Capon 法よりさらに鋭いピークが生じており、推定精度の高さが窺える。

2.5.2 Root-MUSIC

Spectral-MUSIC の推定精度は、式 (2-40) の θ をどの程度の間隔で走査するかによって依存する。したがって、原理的にはオフグリッド推定であるものの、高い分解能を得るには膨大な探索回数が必要になってしまう。これに対し、式 (2-40) の分母 = 0 の方程式

$$\mathbf{a}^H(\theta) \mathbf{E}_N \mathbf{E}_N^H \mathbf{a}(\theta) = 0 \quad (2-42)$$

の根を求根アルゴリズムを用いて求めることで、 θ の走査なしに到来方向を推定する手法を Root-MUSIC [9] という。

まず、 $e^{-j\frac{2\pi}{\lambda}d\sin\theta}$ を ζ とおく。

$$\zeta := e^{-j\frac{2\pi}{\lambda}d\sin\theta} \quad (2-43)$$

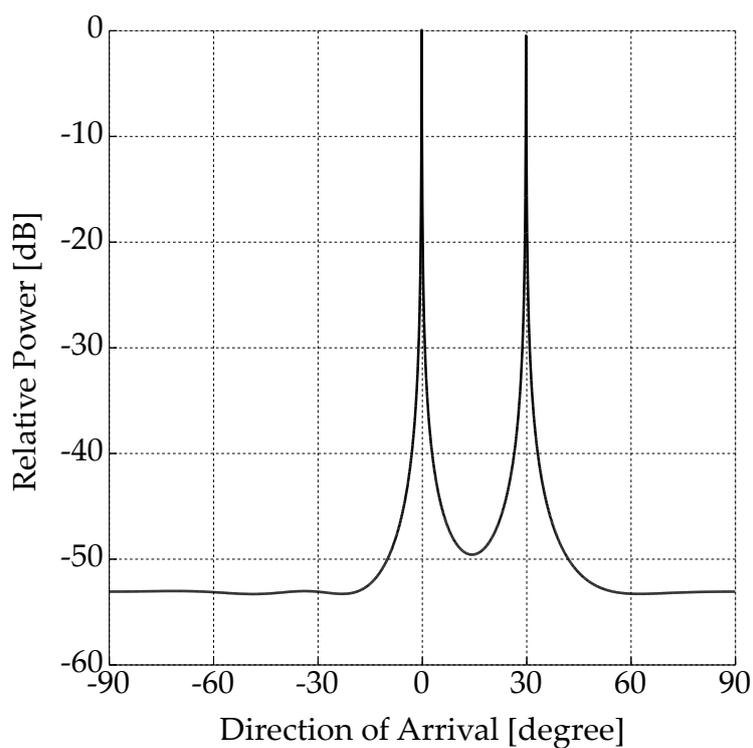


図 2-10 MUSIC スペクトル (アンテナ素子数 : 5, 到来波 : $0^\circ, 30^\circ$)

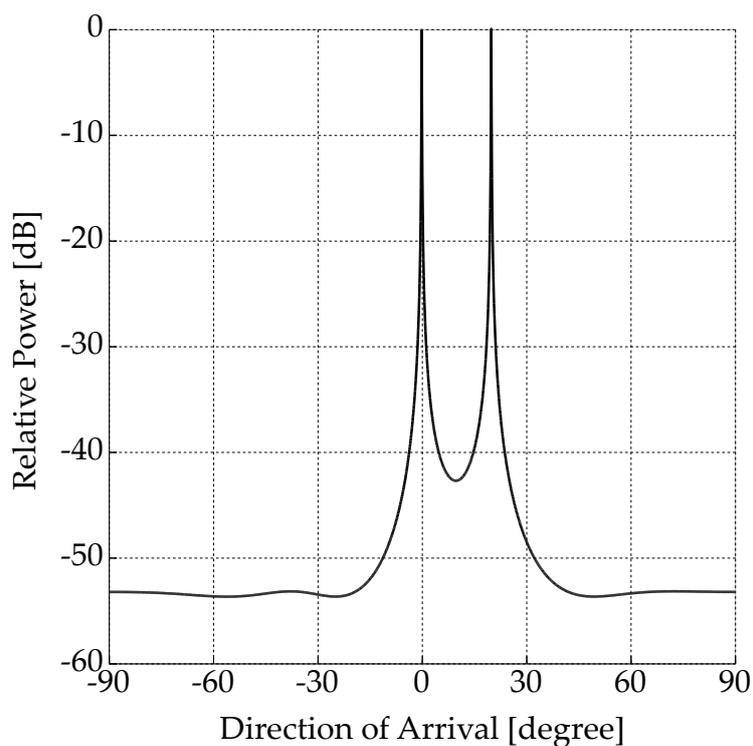


図 2-11 MUSIC スペクトル (アンテナ素子数 : 5, 到来波 : $0^\circ, 20^\circ$)

これにより、モードベクトルは

$$\begin{aligned}\mathbf{a}(\boldsymbol{\theta}) &= \left[1 \quad e^{-j\frac{2\pi}{\lambda}d\sin\theta} \quad e^{-j\frac{2\pi}{\lambda}2d\sin\theta} \quad \dots \quad e^{-j\frac{2\pi}{\lambda}(L-1)d\sin\theta} \right]^T \\ &= \left[1 \quad \zeta \quad \zeta^2 \quad \dots \quad \zeta^{L-1} \right]^T \\ &:= \mathbf{p}(\zeta)\end{aligned}\tag{2-44}$$

と書き直されるので、式 (2-42) は

$$\mathbf{p}^H(\zeta) \mathbf{E}_N \mathbf{E}_N^H \mathbf{p}(\zeta) = 0\tag{2-45}$$

となる。よって、この ζ に関する方程式の根を求めればよい。しかし、これは ζ だけでなくその複素共役 ζ^* を含む複雑な方程式なので、Pisarenko 法 [3] に基づいて以下のように修正し、 ζ のみの方程式に帰着させる [17]。

式 (2-43) から、ここで興味があるのは $|\zeta| = 1$ を満たす根だけである。さらに、

$$\zeta^* = e^{j\frac{2\pi}{\lambda}d\sin\theta} = \zeta^{-1}\tag{2-46}$$

であるから、 $\mathbf{p}^H(\zeta)$ の代わりに $\mathbf{p}^T(\zeta^{-1})$ を用いても式 (2-45) の根は変わらない。この変換により、 ζ^* の項を消去した方程式が得られる。

$$Q(\zeta) = \zeta^{K-1} \mathbf{p}^T(\zeta^{-1}) \mathbf{E}_N \mathbf{E}_N^H \mathbf{p}(\zeta) = 0\tag{2-47}$$

この $Q(\zeta)$ が Root-MUSIC 多項式である。 $Q(\zeta)$ は ζ に関する $2(L-1)$ 次の多項式であり、 $\zeta = e^{-j\frac{2\pi}{\lambda}d\sin\theta_k}$ ($k = 1, 2, \dots, K$) が式 (2-47) の根となる。また、 $\zeta = \gamma e^{j\phi}$ が根であるとき、 $\zeta = \frac{1}{\gamma} e^{j\phi}$ もまた根であるから、式 (2-47) では単位円を挟んで同じ偏角をもつ 2 つの根の組が $L-1$ 個現れることになる。そのうち、到来波に対応する $\gamma = 1$ の根は単位円上の 2 重根であり、それ以外の $\gamma \neq 1$ の根はスプリアス根である。なお、実際の到来方向推定では、有限のスナップショットを用いて受信データ相関行列を得るため、到来波に対応する根も厳密には 2 重根とはならない。しかし、到来方向推定値 $\hat{\boldsymbol{\theta}}_k$ は根の偏角のみを用いて

$$\hat{\boldsymbol{\theta}}_k = \sin^{-1} \frac{\lambda}{2\pi d} \phi_k\tag{2-48}$$

により得られるため、根の絶対値は推定精度に影響しない。

図 2-12 は、図 2-6, 2-8, 2-10 と同じ条件で 2 波が 0° と 30° から到来したときの Root-MUSIC 多項式の根を複素平面上にプロットした一例である。Spectral-MUSIC は円周上を走査して到来方向を推定しているのに対して、Root-MUSIC による推定は複素平面全体の走査に相当するため、一般に Root-MUSIC の推定精度は Spectral-MUSIC より優れている。

2.6 到来方向推定における Cramér-Rao Bound

実際の到来方向推定では有限のスナップショットを用いて受信データ相関行列を得るため、到来波が互いに無相関であっても、式 (2-12) の信号相関行列 \mathbf{S} や雑音相関行列 \mathbf{R}_N が対角行列とならない可能性がある。また、モードベクトル $\mathbf{a}(\theta)$ は θ の正弦を含んでいるため、アレーアンテナの感度はブロードサイド ($\theta = 0^\circ$) 方向が最も良く、エンドファイア ($\theta = \pm 90^\circ$) 方向では分解能が低下する。このように、到来方向推定精度は雑音電力 σ^2 以外にも様々な要因によって変化する。

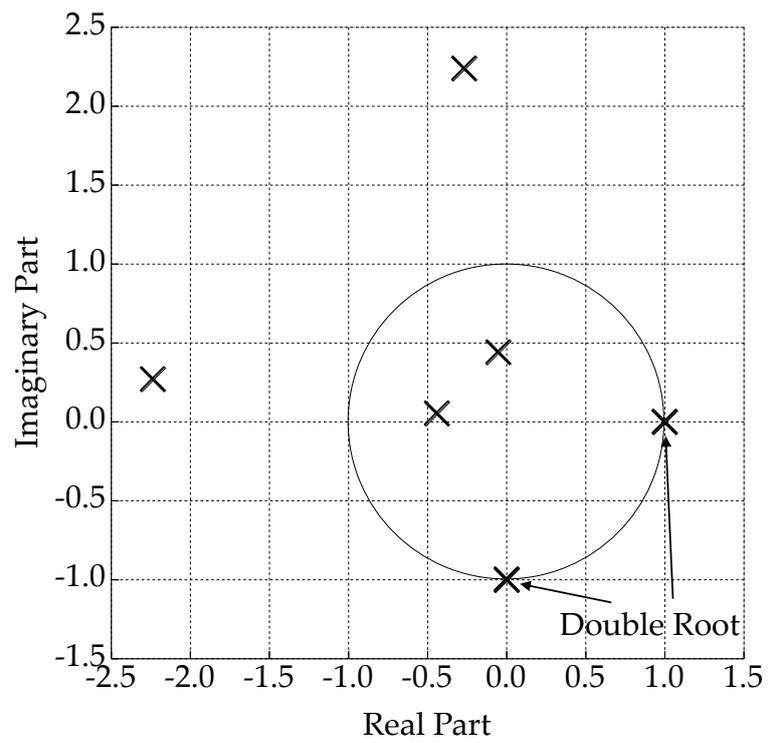
ある SNR やスナップショット数の条件下で到来方向推定を行った場合に達成可能な推定精度を評価する指標として、CRB (Cramér-Rao Bound) [14, 15] がある。これは、雑音が存在する環境における推定誤差の分散の下限値である。スナップショット数が十分に大きい場合、到来方向推定誤差の分散の CRB

$$\text{var}(\hat{\theta}_k) = E[|\hat{\theta}_k - \theta_k|] \quad (2-49)$$

は以下の式で与えられる [4].

$$\begin{aligned} \mathbf{V}(\hat{\boldsymbol{\theta}}) &= \text{diag} \left[\text{var}(\hat{\theta}_1) \quad \text{var}(\hat{\theta}_2) \quad \cdots \quad \text{var}(\hat{\theta}_K) \right] \\ &= \frac{\sigma^2}{2N_s} \left[\Re \left\{ \left(\mathbf{A}'^H \mathbf{P}_N \mathbf{A}' \right) \odot \mathbf{S}^T \right\} \right]^{-1} \end{aligned} \quad (2-50)$$

ここで、 $\Re(\cdot)$ は引数の実部、 \odot はアダマール積を表している。 N_s はスナップショット

図 2-12 Root-MUSIC 多項式の根 (アンテナ素子数 : 5, 到来波 : $0^\circ, 30^\circ$)

数である。また,

$$\mathbf{P}_N = \mathbf{I} - \mathbf{A} (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \quad (2-51)$$

$$\begin{aligned} \mathbf{A}' &= \begin{bmatrix} \frac{\partial \mathbf{a}(\theta_1)}{\partial \theta_1} & \frac{\partial \mathbf{a}(\theta_2)}{\partial \theta_2} & \cdots & \frac{\partial \mathbf{a}(\theta_K)}{\partial \theta_K} \end{bmatrix} \\ &= -j \frac{2\pi}{\lambda} d \begin{bmatrix} 0 & 0 & \cdots & 0 \\ \cos \theta_1 & \cos \theta_2 & \cdots & \cos \theta_K \\ \vdots & \vdots & & \vdots \\ (L-1) \cos \theta_1 & (L-1) \cos \theta_2 & \cdots & (L-1) \cos \theta_K \end{bmatrix} \odot \mathbf{A} \end{aligned} \quad (2-52)$$

である。試行回数が N のとき, RMSE (Root Mean Square Error) の下限は

$$\text{RMSE} = \sqrt{\frac{1}{KN} \sum_{k=1}^K \sum_{n=1}^N \text{var}(\hat{\theta}_k^{(n)})} \quad (2-53)$$

となる。

ただし, CRB は統計量であるため, あらゆる試行において推定誤差が必ず CRB 以上となるわけではない点に注意が必要である。ランダム 2 波推定において RMSE が CRB を下回った場合には, 試行回数が十分でない可能性がある。また, 4.4.6 節や 4.4.7 節で述べるように, 何らかの事前知識に基づいて推定を行った場合にも CRB を下回ることがある。

2.7 まとめ

本章では, アレーアンテナを用いた到来方向推定法について, beamformer 法, Capon 法, Spectral-MUSIC, Root-MUSIC を取り上げて説明した。beamformer 法はメインローブのみを制御しているため, 複数の信号が近接して到来した場合の分離性能は低い。一方で, 同じくメインローブ走査を行うが, 他の方向からの受信電力を最小化するようなウェイトを用いる Capon 法では, そのような 2 波も分離することができる。

メインローブではなく, より鋭いヌルを走査することで到来方向を推定する Spectral-MUSIC は, Capon 法を超える高い角度分解能を実現できることを示した。また, MUSIC スペクトルから得られる方程式を, 角度走査ではなく求根アルゴリズムによっ

て直接解く **Root-MUSIC** は、複素平面全体の走査に相当する手法であるため、**MUSIC** スペクトルが発散せずピークが鈍ってしまうような劣悪な環境でも高い精度で推定が行える。

参考文献

- [1] D. D. Van Veen and K. M. Buckley, “Beamforming: A versatile approach to spatial filtering,” *IEEE ASSP Mag.*, vol. 5, no. 2, pp. 4–24, Apr. 1988, DOI:10.1109/53.665.
- [2] J. Capon, “High resolution frequency-wavenumber spectrum analysis,” *Proc. IEEE*, vol. 57, no. 8, pp. 1408–1418, Aug. 1969, DOI:10.1109/PROC.1969.7278.
- [3] V. F. Pisarenko, “The Retrieval of Harmonics from a Covariance Function,” *Geophys. J. Royal Astron. Soc.*, vol. 33, pp. 347–366, Sept. 1973, DOI:10.1111/j.1365-246X.1973.tb03424.x
- [4] 山田寛喜, “高分解到来波推定の基礎と実際,” 信学会 アンテナ・伝播研究専門委員会, アンテナ・伝搬における設計・解析ワークショップ, No. 33, Oct. 2006.
- [5] R. Kumaresan and D. W. Tufts, “Estimating the Angles of Arrival of Multiple Plane Waves,” *IEEE Trans. Aerosp. and Electronic Syst.*, vol. AES-19, no. 1, pp. 134–139, Jan. 1983, DOI:10.1109/TAES.1983.309427.
- [6] R. O. Schmidt, “Multiple emitter location and signal parameter estimation,” *IEEE Trans. Antennas Propag.*, vol. AP-34, No. 3, pp. 276–280, Mar. 1986, DOI:10.1109/TAP.1986.1143830.
- [7] R. Roy and T. Kailath, “ESPRIT — estimation of signal parameters via rotational invariance techniques,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 37, no. 7, pp. 984–995, Jul. 1989, DOI:10.1109/29.32276.
- [8] 久保田広, “波動光学,” 岩波書店, 東京, 1971.
- [9] B. D. Rao and K. V. S. Hari, “Performance analysis of Root-MUSIC,” *IEEE Trans., Acoust., Speech, Signal Process.*, vol. ASSP-37, No.12, pp.1939–1949, 1989, DOI:10.1109/29.45540.
- [10] M. Haardt and J. A. Nossek, “Unitary ESPRIT: how to obtain increased estimation accuracy with a reduced computational burden,” *IEEE Trans. Sig. Process.*, vol. 43,

-
- no. 5, pp. 1232–1242, May 1995, DOI:10.1109/78.382406.
- [11] M. D. Zoltowski, M. Kauts, and S. D. Silverstein: “Beamspace Root-MUSIC,” *IEEE Trans. Sig. Process.*, vol. 41, no. 1, pp. 344–364, Jan. 1993, DOI:10.1109/TSP.1993.193151.
- [12] G Xu, S. D. Silverstein, R. H. Roy and T. Kailath, “Beamspace ESPRIT,” *IEEE Trans. Sig. Process.*, vol. 42, no. 2, pp. 349–356, Feb. 1994, DOI:10.1109/78.275607.
- [13] M. Pesavento, A. B. Gershman and M. Haardt, “Unitary root-MUSIC with a real-valued eigendecomposition: a theoretical and experimental performance study,” *IEEE Trans. Sig. Process.*, vol. 48, no. 5, pp. 1306–1314, May 2000, DOI:10.1109/78.839978.
- [14] P. Stoica and A. Nehorai, “MUSIC, maximum likelihood, and Cramer-Rao bound,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 37, no. 5, pp. 720–741, May 1989, DOI:10.1109/29.17564.
- [15] P. Stoica and A. Nehorai, “MUSIC, maximum likelihood, and Cramer-Rao bound: further results and comparisons,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 38, no. 12, pp. 2140–2150, Dec. 1990, DOI:10.1109/29.61541.
- [16] Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, D. Kitayama, Y. Kishiyama, “Fundamental Trial on DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E103-B, no. 10, pp. 1127–1135, Oct. 2020, DOI:10.1587/transcom.2019EBP3260.
- [17] 菊間信良, “アレーアンテナによる適応信号処理,” 科学技術出版, 東京, 1998.
- [18] K. Takao, M. Fujita and T. Nishi, “An adaptive antenna array under directional constraint,” *IEEE Trans. Antennas Propag.*, vol. AP-24, no. 5, pp. 662–669, Sept. 1976, DOI:10.1109/TAP.1976.1141411.
- [19] K. Takao and N. Kikuma, “Tamed adaptive antenna array,” *IEEE Trans. Antennas Propag.*, vol. AP-34, no. 3, pp. 388–394, Mar. 1986,
-

DOI:10.1109/TAP.1986.1143821.

- [20] H. Akaike, “A new look at the statistical model identification,” *IEEE Trans. Automatic Control*, vol. AC-19, no. 6, pp. 716–723, Dec. 1974, DOI:10.1109/TAC.1974.1100705.
- [21] M. Wax and I. Ziskind, “Detection of the number of coherent signals by the MDL principle,” *IEEE Trans., Acoust., Speech, Signal Process.*, vol. 37, no. 8, pp. 1190–1196, Aug. 1989, DOI:10.1109/29.31267.
- [22] T. -J. Shan, M. Wax and T. Kailath, “On spatial smoothing for direction-of-arrival estimation of coherent signals,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. ASSP-33, no. 4, pp. 806–811, Aug. 1985, DOI:10.1109/TASSP.1985.1164649.
- [23] R. T. Williams, S. Prasad, A. K. Mahalanabis and L. H. Sibul, “An improved spatial smoothing technique for bearing estimation in a multipath environment,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. ASSP-36, no. 4, pp. 425–432, Apr. 1988, DOI:10.1109/29.1546.
- [24] S. U. Pillai and B. H. Kwon, “Forward/backward spatial smoothing techniques for coherent signal identification,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. ASSP-37, no. 1, pp. 8–15, Jan. 1989, DOI:10.1109/29.17496.

3 整数角度における深層学習の適用可能性の検討

3.1 はじめに

深層学習は、Hinton らの研究 [1,2] を皮切りに画像、音声、言語などの分野で盛んに研究されるようになった、複数の層をもつ深いニューラルネットワーク (Deep Neural Network, DNN) を用いる機械学習の手法の 1 つである。本章では、基本的な順伝播型全結合ネットワークの定式化を行い、その訓練方法と最適化手法、到来方向推定への適用方法について述べた後、等しい電力を有する無相関な狭帯域信号 2 波が互いに重複しない 2 つの整数角度から到来する条件において、訓練および推定シミュレーションを行い、DNN の適応可能性の検討と基本的な性能評価を行う。

アレーアンテナから得られる受信データ相関行列を入力し、離散角度スペクトルが出力されるような DNN を設計する。訓練データの SNR を種々のパターンで変化させた場合の学習曲線を示し、訓練効果について考察する。得られた DNN を用いて到来方向推定シミュレーションを行い、Root-MUSIC [3] との推定精度の比較を行う。さらに、一般に推定が困難とされる近接波の推定精度を評価するため、2 波の到来角度差が 1° である条件で DNN を訓練した場合についても考察する。

3.2 DNN の定式化

図 3-1 に示すように、 I 個の入力を受け付け、 J 個の出力を持つ J ユニットの単層ニューラルネットワークを考える [4]。 i 番目の入力を y_i とすると、 j 番目のユニットの出力 z_j は

$$z_j = f(u_j) \quad (3-1)$$

$$u_j = w_{j,0} + \sum_{i=1}^I w_{j,i} y_i \quad (3-2)$$

と表せる。関数 f は活性化関数、定数 $w_{j,i}$ は j 番目のユニットが y_i に乗算するウェイトである。 $w_{j,0}$ はユニットの出力に平行移動を許容するパラメータであり、バイアス

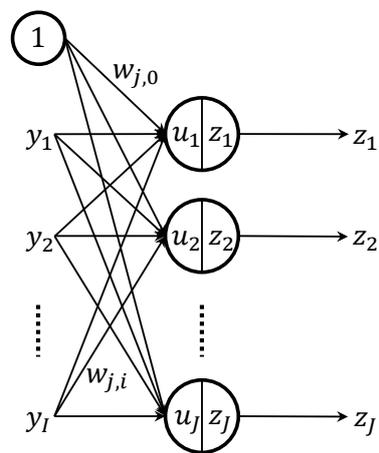


図 3-1 単層ニューラルネットワーク (©2022 IEICE, [5] Fig. 2)

と呼ばれる。ここで、常に 1 を出力する 0 番目のユニットを仮定すると、バイアスはこの入力に乘算するウェイトとみなせるので扱いが簡単になる。

$$u_j = \sum_{i=0}^I w_{j,i} y_i \quad (3-3)$$

このネットワーク全体の出力は以下のようにベクトル形式でまとめられる。

$$\begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_J \end{bmatrix} = \begin{bmatrix} f(u_1) \\ f(u_2) \\ \vdots \\ f(u_J) \end{bmatrix} \quad (3-4)$$

$$\begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_J \end{bmatrix} = \begin{bmatrix} w_{1,0} & w_{1,1} & \cdots & w_{1,I} \\ w_{2,0} & w_{2,1} & \cdots & w_{j,I} \\ \vdots & \vdots & & \vdots \\ w_{J,0} & w_{J,1} & \cdots & w_{J,I} \end{bmatrix} \begin{bmatrix} 1 \\ y_1 \\ \vdots \\ y_I \end{bmatrix} \quad (3-5)$$

式 (3-4), (3-5) を単に

$$\mathbf{z} = f(\mathbf{u}) \quad (3-6)$$

$$\mathbf{u} = \mathbf{W} \begin{bmatrix} 1 \\ \mathbf{y} \end{bmatrix} \quad (3-7)$$

で表すことにする。

DNN は図 3-1 のネットワークを複数連結し多層化したものである。図 3-2 に示すような M 層ニューラルネットワークにおいて、 m 番目の層の出力 $\mathbf{z}^{(m)}$ は

$$\mathbf{z}^{(m)} = f^{(m)}(\mathbf{u}^{(m)}) \quad (3-8)$$

$$\mathbf{u}^{(m)} = \mathbf{W}^{(m)} \begin{bmatrix} 1 \\ \mathbf{z}^{(m-1)} \end{bmatrix} \quad (3-9)$$

である。 $\mathbf{z}^{(0)} = \mathbf{y}$ はこの DNN への入力、 $\mathbf{z}^{(M)} = f^{(M)}(\mathbf{u}^{(M)})$ はこの DNN の出力である。非線形関数を活性化関数とし、ウェイトを適切に調整することで DNN は任意の関数を表現することができるようになる。以降、DNN がもつすべてのパラメータを \mathbf{w} で表し、この DNN に \mathbf{y} を入力したときの出力を $\mathbf{z}(\mathbf{y}; \mathbf{w})$ で表すことにする。

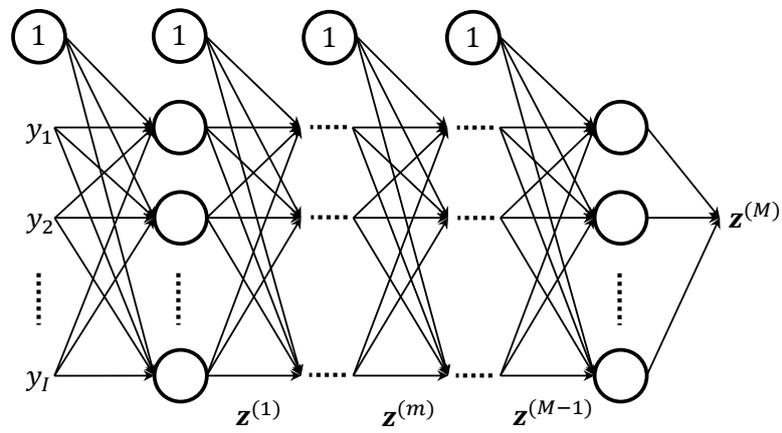


図 3-2 多層ニューラルネットワーク (©2022 IEICE, [5] Fig. 3)

3.3 訓練の枠組み

DNN の訓練とは、ある入力とそのときの正解出力の組からなる N_Y 個の訓練データ $\Upsilon = \{(\mathbf{y}_1, \mathbf{v}_1), (\mathbf{y}_2, \mathbf{v}_2), \dots, (\mathbf{y}_{N_Y}, \mathbf{v}_{N_Y})\}$ が与えられたとき、どの入力 \mathbf{y}_{n_Y} に対しても DNN の出力 $\mathbf{z}(\mathbf{y}_{n_Y}; \mathbf{w})$ が \mathbf{v}_{n_Y} に近くなるようウェイト \mathbf{w} を調整することをいう。一般的な回帰問題では、損失関数として DNN に訓練データを入力したときの 2 乗誤差の和

$$\mathcal{L}(\mathbf{w}) = \frac{1}{2} \sum_{n_Y=1}^{N_Y} \|\mathbf{v}_{n_Y} - \mathbf{y}(\mathbf{x}_{n_Y}; \mathbf{w})\|^2 \quad (3-10)$$

を定義し、これが最小になるよう \mathbf{w} を調整する。これは、現在のウェイト $\mathbf{w}^{(\tau)}$ における損失関数 $\mathcal{L}(\mathbf{w})$ の勾配

$$\nabla \mathcal{L} := \frac{\partial \mathcal{L}}{\partial \mathbf{w}} \quad (3-11)$$

を求め、負の勾配方向にウェイトを更新する繰り返し計算により行われる。

$$\mathbf{w}^{(\tau+1)} = \mathbf{w}^{(\tau)} - \mu \nabla \mathcal{L} \quad (3-12)$$

このときの μ を学習率という。損失関数の勾配計算に用いる訓練データの数はバッチサイズと呼ばれ、このような勾配降下法のうち、特に、バッチサイズが 1、すなわち訓練データを 1 つ入力するたびに勾配計算を行ってウェイトを更新する手法は確率的勾配降下法という。確率的勾配降下法は訓練データが逐次的に入力されるオンライン学習で使用される。

上記の繰り返し計算において学習率はハイパーパラメータであり、設計者が試行的に決定しなければならない。しかし、学習率が大きすぎるとウェイトが損失関数の底に収束できず、小さすぎると収束に時間がかかってしまう。加えて、損失関数が平坦な場所で収束が遅くなる、鞍点に捕獲された場合にそこからの脱出が困難である、などの問題がある。そこで、過去の勾配と訓練回数に応じて適応的に学習率を決定する手法がいくつか提案されている [6–8]。本論文では、これらの手法を発展させた Adam

(Adaptive moment estimation) [9] を用いて学習率を決定する. Adam の擬似コードを Algorithm 1 に示す. ここで, $(\nabla \mathcal{L}_\tau)^2$ はアダマール積 $\mathcal{L}_\tau \odot \mathcal{L}_\tau$ を表しており, それ以外の演算も成分ごとに行われる. $\beta_1^\tau, \beta_2^\tau$ はそれぞれ β_1, β_2 の τ 乗である. 文献 [9] では $\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999, \varepsilon = 10^{-8}$ が推奨されている.

3.4 誤差逆伝播法

勾配降下法により訓練を行うには, 損失関数の勾配 $\nabla \mathcal{L}$ を計算する必要がある. 具体的には, 損失関数を各層の各ウェイトで微分した

$$\frac{\partial \mathcal{L}}{\partial w_{ji}^{(m)}} = \{z(\mathbf{y}_{n_T}; \mathbf{w}) - \mathbf{v}_{n_T}\}^T \frac{\partial z}{\partial w_{ji}^{(m)}} \quad (3-13)$$

を計算する必要がある. ところが, $w_{j,i}$ は

$$\begin{aligned} z(\mathbf{y}_{n_T}; \mathbf{w}) &= \mathbf{f}(\mathbf{u}^{(L)}) \\ &= \mathbf{f}(\mathbf{W}^{(L)} \mathbf{z}^{(L-1)}) \\ &= \mathbf{f}(\mathbf{W}^{(L)} \mathbf{f}(\mathbf{W}^{(L-1)} \mathbf{z}^{(L-2)})) \\ &= \mathbf{f}(\mathbf{W}^{(L)} \mathbf{f}(\mathbf{W}^{(L-1)} \mathbf{f}(\dots \mathbf{f}(\dots) \dots))) \end{aligned} \quad (3-14)$$

のような活性化関数の深い入れ子の中に現れるため, 非常に煩雑で負荷の大きい計算となってしまふ. 誤差逆伝播法 [10] は誤差を出力層から入力層に向かって順に伝播させることで, この微分計算を大幅に簡略化する手法である. 以下にその計算方法を述べる.

式 (3-9) から, $w_{j,i}^{(m)}$ は $u_j^{(m)}$ の中に存在するので, \mathcal{L} を $u_j^{(m)}$ を経由した微分に分解する.

$$\frac{\partial \mathcal{L}}{\partial w_{j,i}^{(m)}} = \frac{\partial \mathcal{L}}{\partial u_j^{(m)}} \frac{\partial u_j^{(m)}}{\partial w_{j,i}^{(m)}} \quad (3-15)$$

式 (3-15) の右辺第 2 項は

$$\frac{\partial u_j^{(m)}}{\partial w_{j,i}^{(m)}} = z_i^{(m-1)} \quad (3-16)$$

Algorithm 1 Adam

Require: $\alpha, \beta_1, \beta_2, \varepsilon, \mathcal{L}$

$$\mathbf{m}_0 = 0$$

$$\mathbf{v}_0 = 0$$

$$\tau = 0$$

while $\mathbf{w}^{(\tau)}$ not converged **do**

$$\tau \leftarrow \tau + 1$$

$$\mathbf{m}_\tau \leftarrow \beta_1 \mathbf{m}_{\tau-1} + (1 - \beta_1) (\nabla \mathcal{L}_\tau)$$

$$\mathbf{v}_\tau \leftarrow \beta_2 \mathbf{v}_{\tau-1} + (1 - \beta_2) (\nabla \mathcal{L}_\tau)^2$$

$$\hat{\mathbf{m}}_\tau \leftarrow \frac{\mathbf{m}_\tau}{1 - \beta_1^\tau}$$

$$\hat{\mathbf{v}}_\tau \leftarrow \frac{\mathbf{v}_\tau}{1 - \beta_2^\tau}$$

$$\mathbf{w}^{(\tau+1)} \leftarrow \mathbf{w}^{(\tau)} - \alpha \frac{\hat{\mathbf{m}}_\tau}{\sqrt{\hat{\mathbf{v}}_\tau} + \varepsilon}$$

end while**return** $\mathbf{w}^{(\tau)}$

3 整数角度における深層学習の適用可能性の検討

と計算できる． $u_j^{(m)}$ の変化は第 $m+1$ 層のユニットの $u_\kappa^{(m)}$ ($\kappa = 1, 2, \dots$) を通してのみ \mathcal{L} に影響するので，式 (3-15) の右辺第 1 項は $u_\kappa^{(m)}$ を経由した微分に分解できる．

$$\frac{\partial \mathcal{L}}{\partial u_j^{(m)}} = \sum_{\kappa} \frac{\partial \mathcal{L}}{\partial u_\kappa^{(m+1)}} \frac{\partial u_\kappa^{(m+1)}}{\partial u_j^{(m)}} \quad (3-17)$$

$$= \sum_{\kappa} \frac{\partial \mathcal{L}}{\partial u_\kappa^{(m+1)}} \left\{ w_{\kappa,j}^{(m+1)} f'(u_j^{(m)}) \right\} \quad (3-18)$$

ここで，

$$\delta_j^{(m)} := \frac{\partial \mathcal{L}}{\partial u_j^{(m)}} \quad (3-19)$$

と定義すると，式 (3-18) は

$$\delta_j^{(m)} = \sum_{\kappa} \delta_j^{(m+1)} \left\{ w_{\kappa,j}^{(m+1)} f'(u_j^{(m)}) \right\} \quad (3-20)$$

と書き直せる． $w_{\kappa,j}^{(m+1)}$ と $u_j^{(m)}$ はある訓練データを順伝播させた際に既知であるから，これは， $\delta_j^{(m)}$ が第 $m+1$ 層で同様の計算を行った $\delta_j^{(m+1)}$ から求められることを表している．

式 (3-16)，(3-19) を式 (3-15) に代入すると

$$\frac{\partial \mathcal{L}}{\partial w_{j,i}^{(m)}} = \delta_j^{(m)} z_i^{(m-1)} \quad (3-21)$$

となる．したがって，目的の微分は，出力層から入力層に向かって順に $\delta_j^{(m)}$ を計算すれば求められることがわかる．損失関数を式 (3-10) の 2 乗誤差，出力層の活性化関数を恒等写像

$$z_j = f(u_j) = u_j \quad (3-22)$$

とした一般的な回帰問題の場合，出力層の $\delta_j^{(M)}$ は

$$\delta_j^{(M)} = \frac{\partial \mathcal{L}}{\partial u_j^{(L)}} = u_j^{(L)} - v_j = z_j^{(L)} - v_j \quad (3-23)$$

であるから，DNN の出力と正解データの差という非常に簡単な計算で求められる．

以上の手順をまとめると，次のようになる．

1. 訓練データを1つ入力して各層の入出力 u_j, z_j を順に計算する（順伝播）
2. 出力層の $\delta_j^{(M)}$ を求める
3. 中間層の $\delta_j^{(m)}$ を $\delta_j^{(m+1)}$ を用いて順に計算する（逆伝播）
4. 各層のウェイト $w_{j,i}^{(m)}$ に関する微分を式 (3-21) から計算する

3.5 到来方向推定への適用

本論文では、DNN への入力としてアレーアンテナから得られた式 (2-15) の受信データ相関行列 \mathbf{R}_{xx} を用いる。アレーアンテナで受信した複素振幅をそのまま用いる方法も考えられるが、この場合はスナップショット数に合わせて入力層が異なる DNN をいくつも用意する必要がある。受信データ相関行列を入力とすれば、スナップショットはこの入力データの精度向上にのみ用いられるため、DNN の構造には影響しない。

\mathbf{R}_{xx} はエルミート行列であるから、実際に入力するのは上三角部分か下三角部分のどちらか一方でよい。本論文では下三角部分を入力するものとする。また、3.2 節で述べた DNN は実数で定義されているので、複素数である非対角成分は実部と虚部に分けて入力する必要がある。対角成分は実数であるためそのまま入力する。したがって、DNN への入力は、まず \mathbf{R}_{xx} の対角成分、つぎに 2 行 1 列成分の実部の虚部、3 行 1 列成分の実部と虚部、以降 L 行 $L-1$ 列成分まで順に取り出して並べたベクトル

$$\mathbf{y} = \begin{bmatrix} r_{1,1} & r_{2,2} & \cdots & r_{L,L} & \Re(r_{2,1}) & \Im(r_{2,1}) \\ & \Re(r_{3,1}) & \Im(r_{3,1}) & \Re(r_{3,2}) & \cdots & \Im(r_{L,L-1}) \end{bmatrix}^T \quad (3-24)$$

となる。ただし、 r は \mathbf{R}_{xx} の成分、 $\Re(\cdot)$ は実部、 $\Im(\cdot)$ は虚部を表している。このとき、列ベクトル \mathbf{y} の次元、すなわち、入力数は L^2 である。

DNN から得られる出力は、図 3-2 に見られるように離散的である。その意味で、DNN を用いた到来方向推定は、圧縮センシングと同様にオングリッド型である。本論文では、このオングリッド推定を素直に適用し、DNN の出力 $\mathbf{z}^{(M)}$ の各要素を事前に設定した角度グリッドと対応させる。角度グリッドが θ_{\min} から θ_{\max} まで $\Delta\theta$ 間隔で構成されているとき、DNN の出力ユニット数は $(\theta_{\max} - \theta_{\min})/\Delta\theta + 1$ となる。DNN

の出力は各グリッドに到来波が存在する確率 [%] とする。したがって、それぞれのユニットは、自身が対応する角度に到来波があれば 100、なければ 0 を出力するよう訓練される。

$$z_j^{(M)} = \begin{cases} 100 & \text{if a wave is incident from the } j\text{th angle bin} \\ 0 & \text{otherwise} \end{cases} \quad (3-25)$$

3.6 推定精度の評価

3.6.1 シミュレーション条件

DNN の推定精度を計算機シミュレーションにより評価する。以下にシミュレーション条件を示す。

基本的な性能評価を行うため、到来波数は 2 とした。式 (2-6) を満たすため、到来波は狭帯域信号である。また、2 波は等電力で、かつ互いに無相関であるとする。オングリッド推定を行う DNN の基本性能を明らかにするため、到来波は、 -60° から 60° までの整数角度から到来するものとした。それぞれの到来方向は推定ごとにランダムであるが、2 つの到来方向は重複しないように設定した。アレーアンテナの素子数は 5 とし、素子間隔は到来波の半波長とする。受信データ相関行列を計算するため、推定ごとに 100 個のスナップショットを用いる。

訓練する DNN は、アンテナ素子数に従い、入力層のユニット数が $L^2 = 25$ である。必要な角度分解能は 1° 、探索範囲は -60° から 60° とした。したがって、121 個の出力ユニットが、 -60° から 60° までの整数角度に対応する角度グリッドを構成する。到来波数は既知とし、推定時には出力された値を降順に 2 つ選択することで到来方向を決定する。

訓練する DNN は、中間層の層数を 4、各層のユニット数を 150 とした。なお、これらのパラメータは最適化されたものではなく、いくつかの試行により経験的に決定されたものである。中間層のユニットの活性化関数は正規化線形関数、出力層のユニットの活性化関数は恒等写像とする。正規化線形関数は図 3-3 のような非線形関数であ

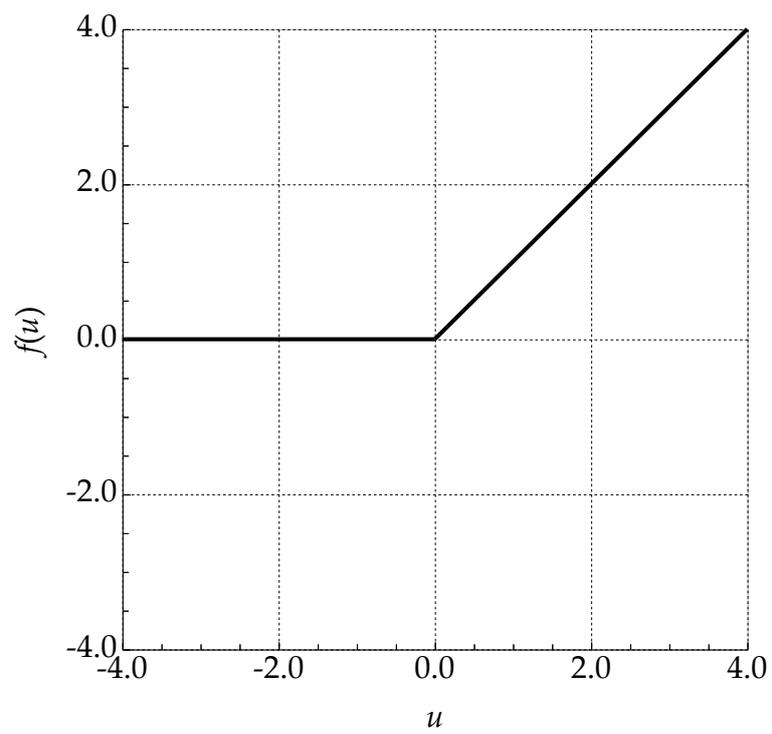


図 3-3 正規化線形関数

り，以下の式で表される．

$$f(u) = \max(u, 0) = \begin{cases} u & \text{for } u \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (3-26)$$

訓練は誤差逆伝播法に基づく確率的勾配降下法によって行う．バッチ学習のほうが一般的であるが，オンライン学習を採用したのは訓練が単純で進捗状況がわかりやすいと考えたからである．バッチ学習は次章で扱っている．学習率の決定には **Adam** を用いる．

推定時と同じく，到来波は -60° から 60° の範囲で互いに重複しない 2 つの整数角度からランダムに到来するものとし，これに白色ガウス雑音を加えて作成した受信データ相関行列を訓練データとして用いる．訓練データ数は 3,000,000 とする．なお，このような受信データ相関行列と真の到来方向からなる大規模な訓練データを実環境で用意することは非常に困難であると考えられる．しかし，計算機シミュレーションにより訓練したモデルでも，少数の実測データを用いて追訓練することで実環境での推定精度が向上することが報告されている [11]．また，計算機シミュレーションにより生成した受信データを，実測データを用いて校正する手法も提案されている [12]．将来的には，これらの手法を組み合わせる訓練を行い，実環境における性能評価を行う必要がある．

訓練時には，100 回の訓練ごとに到来方向，SNR とともにランダムな 100,000 個のバリデーションデータを用いて訓練の進捗を評価する．SNR は 1 信号の電力と雑音電力の比である．バリデーションデータの SNR の範囲は 0 dB から 30 dB とした．推定精度の評価は推定成功率，RMSE (Root Mean Square Error)，絶対値誤差の累積確率分布を用いて評価を行う．推定成功率は，2 波の推定値がどちらも真値と一致した場合を成功，それ以外を失敗として算出する．RMSE は以下の式で表される．

$$\text{RMSE} = \sqrt{\frac{1}{KN} \sum_{k=1}^K \sum_{n=1}^N \left(\hat{\theta}_k^{(n)} - \theta_k^{(n)} \right)^2} \quad (3-27)$$

ここで， N は試行回数である．累積確率分布は，推定された到来方向それぞれの絶対値誤差の累積確率とする．以降， $N = 100,000$ として評価を行う．

3.6.2 訓練データの SNR と学習曲線

訓練データとして、以下の 6 パターンで SNR が変化する受信データ相関行列と、そのときの正解出力ベクトルの組を用意する。

- (i) 0 dB で一定 (“0 dB”)
- (ii) 30 dB で一定 (“30 dB”)
- (iii) 0 dB から 30 dB まで右肩上がりに上昇 (“increase”)
- (iv) 0 dB から 30 dB まで 5 dB 刻みで右肩上がりに上昇 (“stepwise”)
- (v) 30 dB から 0 dB まで右肩下がりに低下 (“decrease”)
- (vi) 0 dB から 30 dB の範囲でランダム (“random”)

図 3-4 は、横軸を訓練済みのデータ数、縦軸を訓練データの SNR として、訓練データ 3,000,000 個の SNR の変化を示している。

図 3-5 に、上記 6 パターンの訓練データを 100 個学習する度にバリデーションデータを使用して求めた推定成功率の学習曲線を示す。横軸が訓練済みのデータ数、縦軸が推定成功率である。推定成功率は非常に細かく振動しており、訓練が終了した時点が最も推定成功率が高いとは限らないことがわかる。0 dB” と “decrease” で訓練した場合を除いて、推定成功率は訓練データ数の上昇に伴って徐々に改善していくものの、約 1,500,000 個を訓練した辺りから改善幅が小さくなっている。訓練を途中で打ち切る場合、その訓練データ数が最適であったかを判断するのは難しいと考えられる。最も高い推定成功率を示した訓練データ数は表 3-1 の通りである。“0 dB” で訓練した DNN はどのデータ数においても良好な推定成功率を示していない。SNR の低い訓練データでは受信データ相関行列の特徴が雑音に埋もれてしまい、訓練が正しく進まないと考えられる。

図 3-6 は、訓練データを 100 個学習する度にバリデーションデータを使用して求めた RMSE の学習曲線である。“30 dB” で訓練した DNN の RMSE は約 1,000,000 個の訓練データ数で最良の RMSE を示したあと、訓練が進むごとに徐々に悪化している。

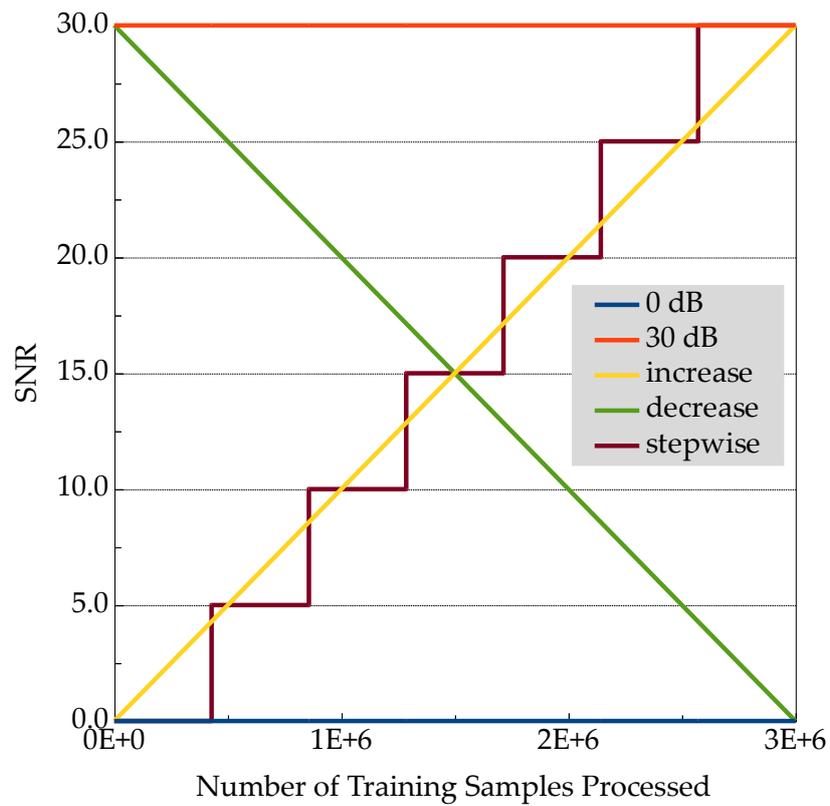


図 3-4 訓練データの SNR の変化パターン (ランダムに変化するパターンは未記載)

(©2020 IEICE, [13] Fig. 5)

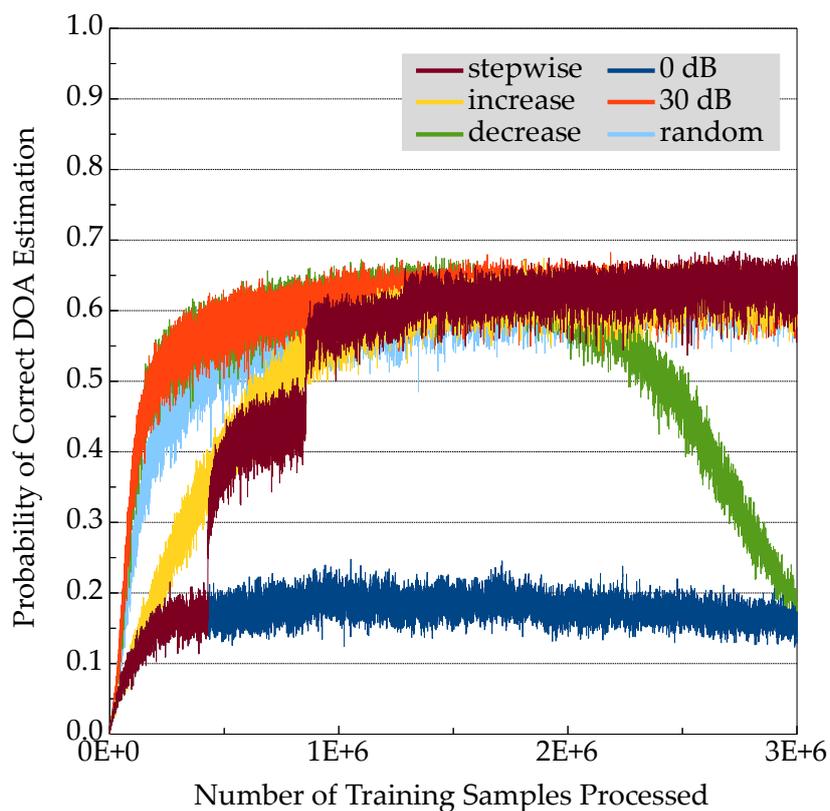


図 3-5 訓練データを 100 個学習する度にバリデーションデータを使用して求めた推定成功率の学習曲線 (©2020 IEICE, [13] Fig. 6)

表 3-1 最大推定成功率を示した訓練データ数

Training data sets	The number of learning cycles showing the highest success rate
(i) 0 dB	1,052,900
(ii) 30 dB	2,186,700
(iii) increase	1,895,200
(iv) stepwise	2,748,600
(v) decrease	1,424,000
(vi) random	2,995,500

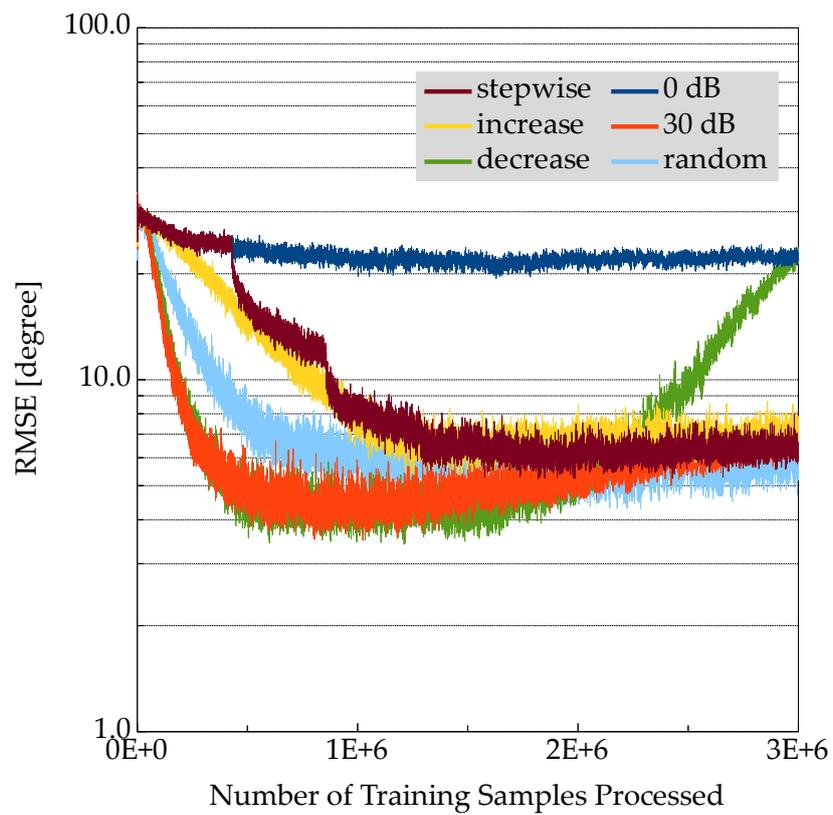


図 3-6 訓練データを 100 個学習する度にバリデーションデータを使用して求めた RMSE の学習曲線 (©2020 IEICE, [13] Fig. 7)

これは、オーバーフィッティングが発生していることを示唆している。図 3-5 の推定成功率の学習曲線ではこのような特徴は見られないことから、オーバーフィッティングが発生すると、推定に失敗したときの推定誤差が大きくなることが予想される。本論文では、オングリッド推定を行う DNN の推定成功率に注目して評価するため、以降では、表 3-1 の最も高い推定成功率を示した訓練データ数時点の DNN を用いるものとする。

3.6.3 訓練データの SNR と推定精度

SNR パターン (i) から (vi) に従って訓練し、表 3-1 に示したデータ数で打ち切った DNN を用いて推定シミュレーションを行ったときの推定成功率と RMSE を図 3-7、3-8 にそれぞれ示す。これらのグラフの横軸は推定時の SNR を表している。参考として、Root-MUSIC [3] の推定成功率と RMSE も合わせて示す。Root-MUSIC では実数値の角度が推定されるため、得られた推定値を最も近い整数角度に丸めた上で推定成功率と RMSE を求めている。なお、図 3-7、3-8 の推定成功率と RMSE が図 3-5、3-6 と異なるのは、図 3-5、3-6 は SNR が 0 dB から 30 dB の範囲でランダムに設定したバリデーションデータを用いて求めたためである。

図 3-7 では、“30 dB” と “stepwise” の SNR パターンで訓練した DNN が高 SNR 時に最も高い推定成功率を示している。両者を比較すると “stepwise” のほうがわずかに推定成功率が高いものの、RMSE は “30 dB” と比較して明らかに劣化していることがわかる。このように、“30 dB” のような高 SNR のデータを用いて訓練した DNN は、SNR が 10 dB から 30 dB の範囲では、成功率だけでなく RMSE の面でも高い性能を発揮すると言える。

DNN と Root-MUSIC の推定精度を比較すると、DNN は推定成功率と RMSE ともに Root-MUSIC より劣っていることがわかる。この性能差は明らかに、DNN の訓練が不十分であるか、DNN の構造が最適化されていないことを示している。DNN 構造の最適化とオングリッド推定特有の問題の解決については、次章 4.4.2 節から 4.4.5 節で述べている。しかし、現在の DNN の構成でも、3.6.5 節で示すように優位性を得る

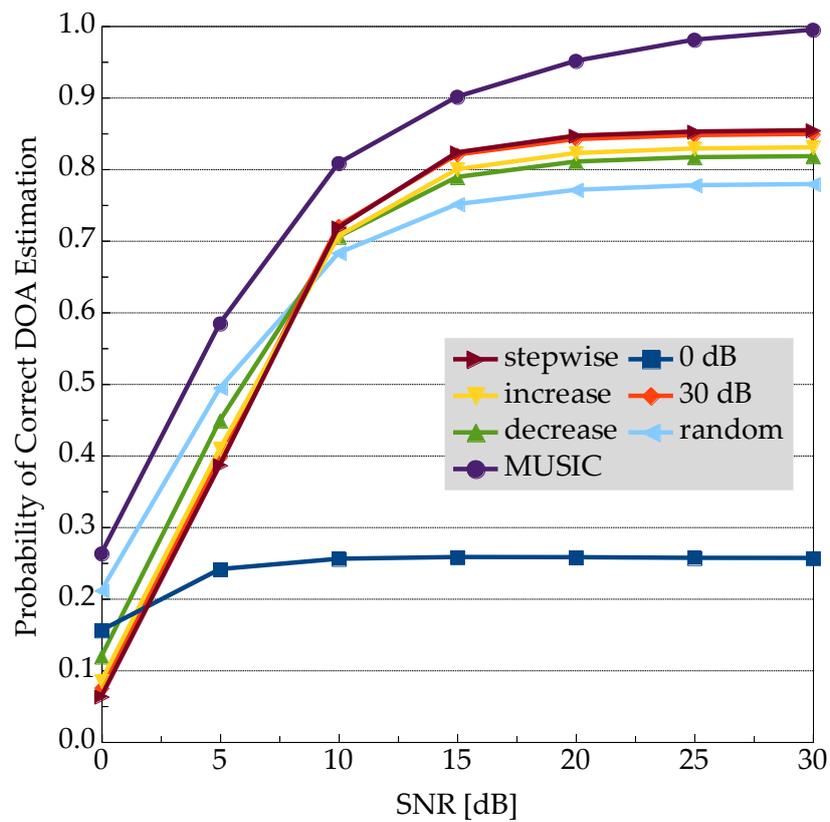


図 3-7 (i) から (vi) の SNR パターンに従って訓練した DNN の推定成功率
(©2020 IEICE, [13] Fig. 8)

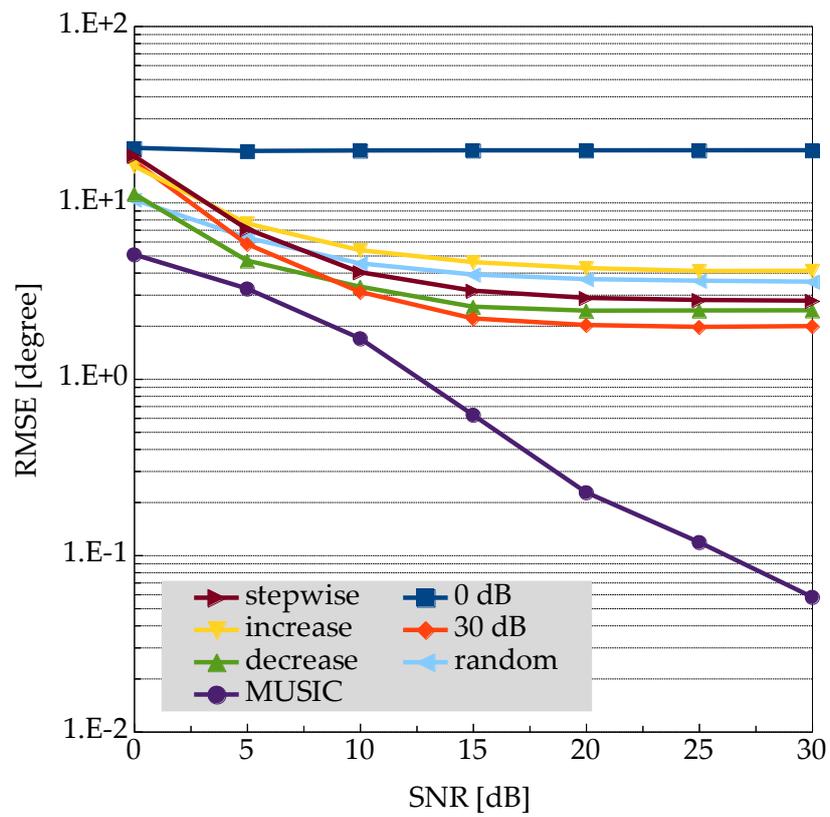


図 3-8 (i) から (vi) の SNR パターンに従って訓練した DNN の RMSE
(©2020 IEICE, [13] Fig. 9)

ことができる。

“random”のSNRパターンで訓練したDNNは、SNR 10 dBから30 dBの範囲では、“30 dB”、“increase”、“stepwise”、“decrease”と比較して推定成功率が低いものの、SNR 0 dBから10 dBの範囲における推定成功率は他のDNNよりも高い。したがって、幅広い観測条件に適したDNNは、訓練データのSNRをランダムに変化させた場合に得られると言える。次節の評価では、この“random”のSNRパターンで訓練したDNNを用いている。一方で、“30 dB”や“stepwise”のように、訓練の後半にSNRの高いデータを使用したDNNは、高SNR時の推定に適したものとなっている。

3.6.4 推定誤差の累積確率

図3-9は、“random”のSNRパターンで訓練したDNNを用いて推定を行った場合の、SNR 30 dBにおける推定誤差の絶対値の累積確率を示している。参考として、Root-MUSICの累積確率も示している。推定成功率は、2つの到来方向がどちらも正しく推定された場合を成功としていた。具体的には、図3-7に示したように、“random”はSNR 30 dBのとき、合計100,000回の推定のうち22%で失敗している。しかし、図3-9からわかるように、到来した合計200,000波のうち約86%は誤差が0であり、誤差が 1° 以内に収まる確率は97%を超えている。DNNの推定成功率はRoot-MUSICの推定成功率には及ばないものの、整数角度の条件下では、主に行列とベクトルの乗算によって推定を行うDNNは、推定時の計算の複雑さを適度に抑えながら図3-9のような高精度を実現している点で非常に魅力的である。

3.6.5 近接波の推定に特化したDNN

これまでの検討で、推定性能は訓練データに依存することがわかった。例えば、ランダムなSNRのデータを用いて訓練したDNNは広い範囲のSNRに対して、高SNRのデータを用いて訓練したDNNは高SNR時の推定で良好に動作する。これは、ある特定の到来環境に特化したDNNを設計することが可能であることを示している。本節では、一般に推定が困難とされる近接到来波に適したDNNの構築を試みる。

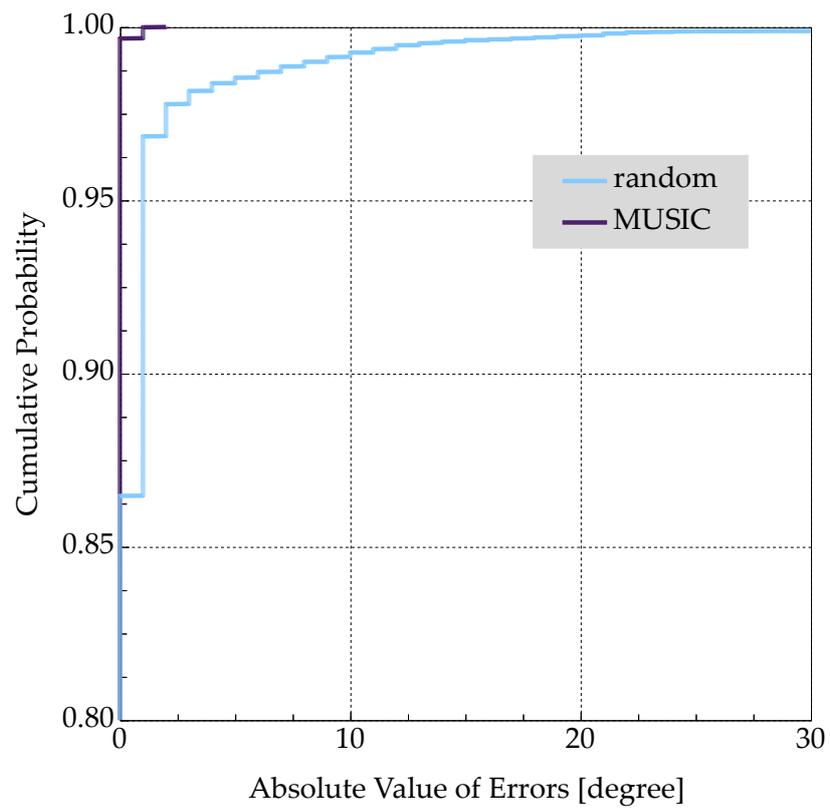


図 3-9 推定誤差の絶対値の累積確率 (©2020 IEICE, [13] Fig. 10)

3 整数角度における深層学習の適用可能性の検討

DNN の訓練は、2 波の到来角度差が 1° である、つまり $|\theta_1 - \theta_2| = 1^\circ$ である条件下で作成した訓練データ 300,000 個を用いて行う。訓練データ数が前節までの検討と比較して少ないのは、 1° 近接波の推定は一般に困難であるものの、訓練しなければならぬ到来方向の組み合わせはランダム 2 波推定の場合と比較して少ないためである。訓練データの SNR はランダムに設定した。その他の条件は、3.6.1 節と同じである。

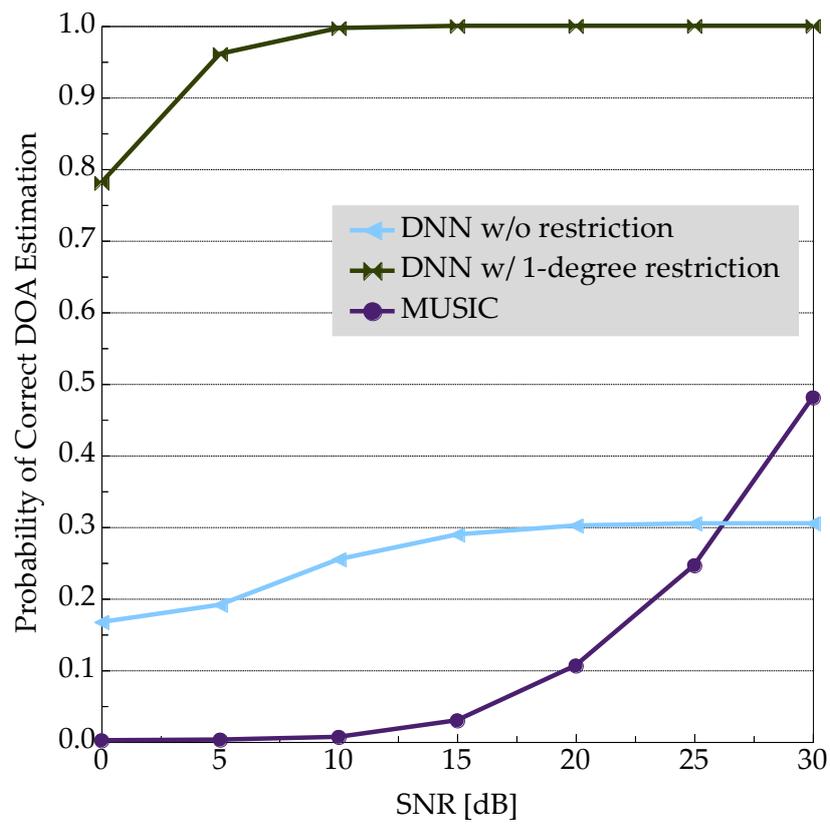
この DNN を用いて 1° 近接波の推定を行ったときの推定成功率を図 3-10 に示す。参考として、Root-MUSIC と、3.6.2 節から 3.6.4 節で検討した“random”の SNR パターンで訓練した DNN の推定成功率も示している。

SNR が 30 dB のときの推定成功率は、角度差の制約なしに訓練した DNN が約 30%、Root-MUSIC でも約 50% となっていることから、一般に 1° 近接波の推定は困難であることがわかる。これに対し、 $|\theta_1 - \theta_2| = 1^\circ$ の制約のもと訓練した DNN は、SNR が 20 dB 以上の場合に 100% の推定成功率を達成している。このように特定の環境に合わせて推定器を設計することができる点は、機械学習を利用した推定に特有のものである。また、このような DNN を他の技術と補完的に利用できる可能性を示している。

3.6.6 汎用 DNN と専用 DNN を用いた並列推定

上述のように、 1° 近接波推定用に設計された DNN は、他の推定器と並列に使用することができる。本節では、3.6.2 節から 3.6.4 節で検討した“random”の SNR パターンで訓練した DNN と、前節で検討した 1° 近接波に特化した DNN を並列に使用して推定を行った場合について検討する。ここで、組み合わせは理想的に行われたと仮定し、推定成功率は、2 つの DNN のうち少なくとも 1 つの DNN が、2 つの到来方向をどちらも正しく推定した場合を成功として算出した。具体的な選択方法については、5.2 節で検討している。

図 3-11 は、“random”の SNR パターンで訓練した DNN を用いてランダム 2 波推定を行った場合と、それに 1° 近接波に特化した DNN を組み合わせて推定を行った場合の推定成功率を示している。ランダム 2 波推定において 1° 近接条件となる確率は約 1.6% であるため、このような条件に備えることはそれほど大きな改善とはならない。

図 3-10 2 波の到来角度差を 1° としたときの推定成功率

(©2020 IEICE, [13] Fig. 11)

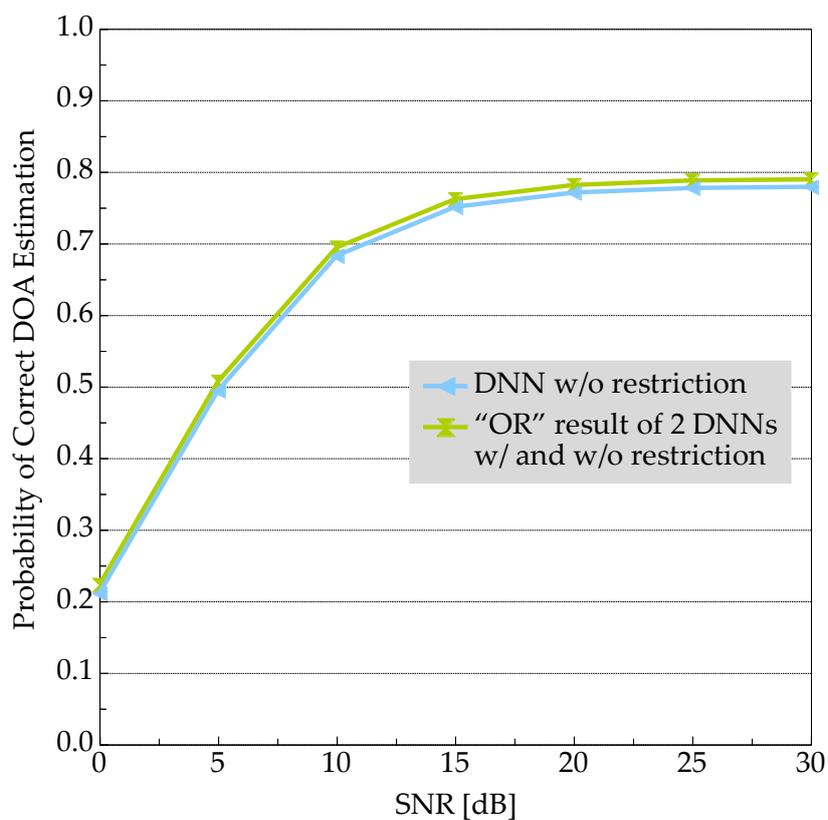


図 3-11 “random” の SNR パターンで訓練した DNN と 1° 近接波に特化した DNN を組み合わせた場合の推定成功率 (©2020 IEICE, [13] Fig. 12)

しかし、単独で推定した場合と比較して推定成功率が確実に向上している。この特性は、様々な条件で訓練した DNN の組み合わせによって推定精度が向上することを示している。

3.7 まとめ

本章では、基本的な順伝播型全結合ネットワークの定式化と誤差逆伝播法による訓練について説明し、線形アレーアンテナに等しい電力を有する無相関な狭帯域信号 2 波が互いに重複しない 2 つの整数角度から到来する条件において、DNN の基本的な性能評価を行った。訓練データの SNR を 6 種のパターンで変化させた結果、SNR が 30 dB で一定のデータを学習した DNN が高 SNR 時の推定に最も適していること、SNR がランダムに変化するデータで訓練した DNN は幅広い SNR に適したものになることが確認された。SNR がランダムに変化するデータで訓練した DNN を用いたランダム 2 波推定において、推定成功率は SNR 30 dB 時の推定でも 80% に満たないものの、絶対値誤差が 0° または 1° となる割合は約 97% であった。訓練には時間を要するものの、推定時には簡易な計算により高い推定精度が得られることが確認された。 1° 近接という厳しい到来条件であっても、 1° 近接条件で訓練した DNN を用いることで極めて高い精度で推定が行えることが確認された。このような、ある特定の環境に特化したモデルを補完的に用いることでランダム 2 波推定の精度をさらに改善できることを示した。

参考文献

- [1] G. E. Hinton, S. Osindero, and Y. Teh, “A fast learning algorithm for deep belief nets,” *Neural Computation*, vol. 18, no. 7, pp. 1527–1544, July 2006, DOI:10.1162/neco.2006.18.7.1527.
- [2] G. E. Hinton and R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol. 313, no. 5786, pp. 504–507, July 2006, DOI:10.1126/science.1127647.
- [3] B. D. Rao and K. V. S. Hari, “Performance analysis of Root-MUSIC,” *IEEE Trans., Acoust., Speech, Signal Process.*, vol. ASSP-37, No.12, pp.1939–1949, 1989, DOI:10.1109/29.45540.
- [4] 岡谷貴之, “深層学習,” 講談社, 東京, 2015.
- [5] Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, T. Sato, Y. Kishiyama, “Accuracy Improvement in DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E105-B, no. 5, May 2022 (Advance publication), DOI:10.1587/transcom.2021EBT0001.
- [6] J. Duchi, E. Hazan, and Y. Singer. “Adaptive subgradient methods for online learning and stochastic optimization.” *Journal of Machine Learning Research*, vol. 12, no. 61, pp. 2121–2159, 2011.
- [7] G. Hinton, N. Srivastava, and K. Swersky, Lecture 6e - rmsprop: Divide the gradient by a running average of its recent magnitude, *Neural Networks for Machine Learning*, 2012.
- [8] M. D. Zeiler, “ADADELTA: An adaptive learning rate method,” arXiv:1212.5701v1, Dec. 2012.
- [9] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” arXiv:1412.6980v9, Jan. 2017.

-
- [10] D. E. Rumelhart, G. E. Hinton and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986, DOI:10.1038/323533a0.
- [11] T. Jikyo, T. Yamanishi, T. Kamada, R. Nishide, C. Ohta, K. Oyama and T. Ohkawa, “A study on outdoor localization method based on deep learning using model-based received power estimation data of low power wireless tag,” *IEICE Commun. Express*, vol. 8, no. 12, pp. 524–529, Oct. 2019, DOI:10.1587/comex.2019GCL0032.
- [12] 山田寛喜, “高分解能到来方向推定のためのアレーキャリブレーション手法,” 信学論 (B) , vol. J92-B, no. 9, pp. 1308–1321, Sept. 2009.
- [13] Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, D. Kitayama, Y. Kishiyama, “Fundamental Trial on DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E103-B, no. 10, pp. 1127–1135, Oct. 2020, DOI:10.1587/transcom.2019EBP3260.

4 実数角度における深層学習の適用可能性の検討

4.1 はじめに

第3章では、オングリッド推定と親和性の高い整数角度で到来する条件において DNN の適用可能性を検討した。しかし、実際の信号の到来方向は実数であるため、離散的な出力しか持たない DNN の利用法をさらに検討する必要がある。本章では、Google が開発した機械学習向けのオープンソースライブラリである TensorFlow [1] を用いて、DNN の出力として設定した角度グリッドに拘束されないランダムな実数角度から到来する条件において、DNN の適用可能性を検討する。

その過程で、整数角度の条件では見られなかった新たな問題が判明した。具体的には、DNN の出力として設定した角度グリッドの境界上に信号が到来した場合に、境界を挟んで隣り合う2つのユニットの出力が大きくなり、最近傍ユニットの推定に失敗する可能性があるというものである。この問題を解決するため、角度グリッドの境界が重ならないように配置した2つの DNN を組み合わせて推定する手法を提案する。加えて、整数角度での検討と同様に、到来角度差が 1° である条件に特化した DNN を構築し、その性能を評価する。また、その DNN を角度差の制約なしに訓練した DNN と理想的に組み合わせた場合の推定精度についても検討する。

以降では、新たに適用する最適化手法である Batch Normalization [2] と、再検討した DNN の到来方向推定への適用方法について説明した後、計算機シミュレーションによる性能評価について述べる。

4.2 Batch Normalization

3.4 節で述べた誤差逆伝播法 [3] により、複雑な微分計算をせずとも損失関数の勾配 $\nabla \mathcal{L}$ を求められるようになった。しかし、勾配計算が出力層から入力層へ向かう線形演算となった代償として、ウェイトの大小によって、各層を伝播する過程で勾配が急速に増大したり、逆に消失したりする勾配消失問題が起こるようになった。これは

DNN の訓練における大きな課題であり、これを解決するため自己符号化器 [4] を用いた事前学習や Dropout [5] によりネットワークの表現力を制限するなどの手法が用いられてきた。Batch Normalization [2] は、これらの手法に代わり、勾配の消失を抑圧すると同時に過学習やウェイトの初期値依存性の低減、学習速度の向上等が見込める強力な手法として知られている。

Batch Normalization は各ユニットの活性化関数への入力 $u_j^{(m)}$ をバッチ単位で平均 0、分散 1 に正規化したあと、新しい平均と分散を付与する手法である。つまり、Batch Normalization を適用したときの各ユニットの出力 $z_{BN_j}^{(m)}$ は以下のように変換される。

$$\mu_{NN_j}^{(m)} = \frac{1}{B} \sum_{b=1}^B u_{j,b}^{(m)} \quad (4-1)$$

$$\sigma_{NN_j}^{(m)} = \sqrt{\frac{1}{B} \sum_{b=1}^B (u_{j,b}^{(m)} - \mu_{NN_j}^{(m)})^2} \quad (4-2)$$

$$u_{BN_j}^{(m)} = \frac{u_{j,b}^{(m)} - \mu_{NN_j}^{(m)}}{\sigma_{NN_j}^{(m)}} \quad (4-3)$$

$$z_{BN_j}^{(m)} = f\left(\sigma_{BN_j}^{(m)} u_{BN_j}^{(m)} + \mu_{BN_j}^{(m)}\right) \quad (4-4)$$

ここで、 B はバッチサイズである。

4.3 DNN の到来方向推定への適用方法

DNN への入力は、3.5 節で式 (4-5) に示した、式 (2-15) の受信データ相関行列 \mathbf{R}_{xx} の下三角部分を順に取り出して並べたベクトル

$$\mathbf{y} = \begin{bmatrix} r_{1,1} & r_{2,2} & \cdots & r_{L,L} & \Re(r_{2,1}) & \Im(r_{2,1}) \\ & \Re(r_{3,1}) & \Im(r_{3,1}) & \Re(r_{3,2}) & \cdots & \Im(r_{L,L-1}) \end{bmatrix}^T \quad (4-5)$$

とする。

本章では、機械学習向けのオープンソースライブラリである TensorFlow [1] を用いて DNN の訓練と評価を行う。Batch Normalization, Adam [6] の適用や、クラス分類で一般的に用いられている値域を念頭に、DNN の出力は、 -60° から 60° までの各方向に到来波が存在する確率とする。角度分解能は 1° とする。したがって、121 個の出

カユニットがあり、それぞれのユニットは、自身が対応する角度に到来波があれば 1、なければ 0 を出力するよう訓練される。

$$z_j^{(M)} = \begin{cases} 1 & \text{if a wave is incident from the } j\text{th angle bin} \\ 0 & \text{otherwise} \end{cases} \quad (4-6)$$

4.4 推定精度の評価

4.4.1 シミュレーション条件

5 素子半波長等間隔線形アレーアンテナに、等しい電力を有する狭帯域無相関波 2 波が、 -60° から 60° の範囲でランダムに到来するモデルにおいて、訓練および推定シミュレーションを行う。3 章で行った整数角度での検討と異なり、到来方向は DNN の出力として設定した角度グリッドに拘束されないランダムな実数角度である。スナップショット数は 100 とし、この 100 個のデータから相関行列を計算する。

訓練する DNN は、アンテナ素子数に従い、入力ユニット数を 25 とする。出力ユニット数は 4.3 節で述べたように 121 である。中間層の層数は 2 から 5 の 4 通り、ユニット数は出力ユニット数の 1.0, 1.5, ..., 5.0 倍である 121, 182, 242, 303, 363, 424, 484, 545, 605 の 9 通りを考える。したがって、36 通りの DNN を訓練する。中間層のユニットの活性化関数は図 3-3 に示した正規化線形関数

$$f(u) = \max(u, 0) = \begin{cases} u & \text{for } u \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (4-7)$$

とする。出力層のユニットの活性化関数は、出力値が確率であるという設計に従い、0 から 1 の値域をもつ標準シグモイド関数

$$f(u) = \frac{1}{1 + e^{-u}} \quad (4-8)$$

とする。これは図 4-1 のような非線形関数である。

訓練に使用するデータにおいても、到来方向は -60° から 60° の範囲でランダムとする。SNR は 1 信号の電力と雑音電力の比である。3 章では、訓練データの SNR が推定精度に与える影響を検討したが、本章では簡単のため 20 dB 一定とした。この条

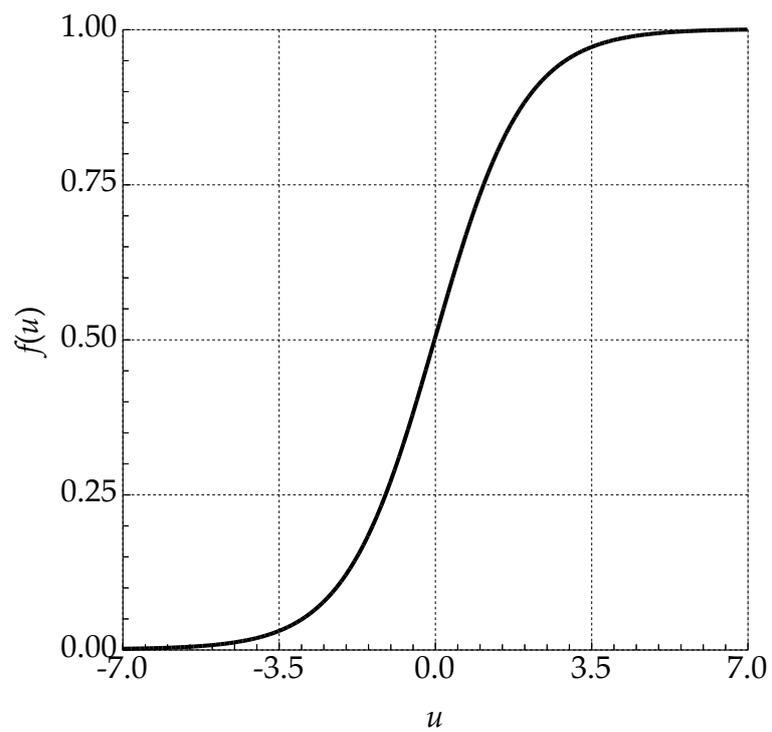


図 4-1 標準シグモイド関数

件で受信データ相関行列を 210,000 個生成し、そのうち 200,000 個を訓練データ、残りの 10,000 個をバリデーションデータとして使用する。

訓練は誤差逆伝播法を用いたバッチ学習により行う。ただし、学習率は過去の勾配から適応的に決定する手法である Adam を用いて変化させる。エポック数は最大 999、バッチサイズは 128 とする。したがって、訓練データ全体は 999 回繰り返し入力され、128 個のデータが入力されるごとにウェイトが更新される。また、各ユニットへの入力をバッチ単位で平均 0、分散 1 に正規化する Batch Normalization を適用する。

訓練の進捗は、各エポック毎にバリデーションデータを使用して求めた推定成功率により評価する。推定成功率は、2 波の推定値がどちらも誤差 $\pm 0.5^\circ$ 以内、すなわち、最も近いユニットであった場合を成功、それ以外を失敗として算出する。過学習による特性の劣化を防ぐため、最終的に推定に用いる DNN はバリデーションで最も推定成功率が高かったエポックのものとする。

推定精度の評価は推定成功率、RMSE を用いて行う。RMSE は以下の式で表される。

$$\text{RMSE} = \sqrt{\frac{1}{KN} \sum_{k=1}^K \sum_{n=1}^N (\hat{\theta}_k^{(n)} - \theta_k^{(n)})^2} \quad (4-9)$$

ここで、 N は試行回数である。以降、 $N = 100,000$ として評価を行う。

4.4.2 DNN パラメータの比較

訓練の結果得られた 36 通りの DNN を用いてランダム 2 波推定を行ったときの推定成功率と RMSE を表 4-1、4-2 にそれぞれ示す。推定時データの SNR は 20 dB である。DNN A の定義については、以降で述べる。

最も高い推定成功率を示したのは中間層の層数が 4、ユニット数が 363 の DNN であった。このときの推定成功率は 83.7% である。最も低い RMSE を示したのは中間層の層数が 4、ユニット数が 424 の DNN であった。このときの RMSE は 1.090° である。それぞれ表 4-1、4-2 において太字で示している。しかしながら、中間層の層数が 3 以上、ユニット数が出力層のユニット数の 2 倍である 242 以上であれば、概ね最大推定成功率に近い特性が得られることがわかる。本論文では、オングリッド推定を行

表 4-1 DNN A の層数, ユニット数と推定成功率 (©2022 IEICE, [7] Table 1)

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	0.642	0.761	0.700	0.705
	182	0.760	0.809	0.812	0.781
	242	0.797	0.827	0.837	0.833
	303	0.810	0.831	0.834	0.834
	363	0.813	0.832	0.837	0.836
	424	0.813	0.836	0.836	0.828
	484	0.816	0.833	0.831	0.833
	545	0.820	0.836	0.829	0.826
	605	0.820	0.835	0.833	0.829

表 4-2 DNN A の層数, ユニット数と RMSE (©2022 IEICE, [7] Table 2)

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	9.834	3.786	5.614	5.023
	182	5.081	2.381	2.482	4.474
	242	3.886	1.807	2.007	3.824
	303	3.106	1.746	2.257	3.539
	363	3.116	1.628	1.226	2.753
	424	2.878	1.408	1.090	4.355
	484	2.597	1.486	1.099	2.242
	545	2.419	1.384	3.942	2.656
	605	2.325	1.477	2.482	4.581

う DNN の推定成功率に注目して評価するため、以降では、表 4-1 で最も高い推定成功率を示した中間層の層数が 4、ユニット数が 363 の DNN を用いるものとする。後述する他の DNN と区別するため、この DNN を DNN A と表記する。

図 4-2 は、各エポック毎に DNN A の推定成功率と RMSE を 10,000 個のバリデーショndata、または 100,000 個の推定データを用いて評価した学習曲線である。バリデーショndata に対しては、どちらも訓練が進む毎に徐々に改善していく様子が見て取れる。しかし、各々の値は振動しており、訓練の最後のエポックで最良の DNN が得られるわけではない。表 4-3 は、表 4-1 の最大推定成功率が得られたエポック数を示している。中間層の層数が 4、ユニット数が 363 のときは 755 エポックで最大の推定成功率が得られたため、DNN A のウェイトとしてこのエポックのものを使用している。

一方で、推定データによる評価では、RMSE の学習曲線が約 200 エポックを境に緩やかに悪化していることがわかる。これは RMSE の最適化においては過学習が起こっていることを示唆しており、RMSE の観点から最適な DNN を選択するには 10,000 個のバリデーショndata では不十分であると言える。しかし、推定成功率の学習曲線はバリデーショndata で得られた学習曲線とほとんど変わらないため、推定成功率の最適化においては 10,000 個のバリデーショndata で十分に検証が行えている。

4.4.3 推定精度の比較

中間層の層数が 4、ユニット数が 363 である DNN A を用いてランダム 2 波推定を行ったときの推定成功率と RMSE を図 4-3, 4-4 にそれぞれ示す。これらのグラフの横軸は推定時の SNR を表している。参考として、Root-MUSIC [8], HQR (Half-Quadratic Regularization) [9] の推定成功率と RMSE も併せて示している。なお、文献 [9] にある HQR のハイパーパラメータ μ , ε , p は、いくつかの試行により、経験的にそれぞれ 10, 3×10^{-6} , 3×10^{-6} とした。図 4-4 には CRB (Cramér-Rao Bound) [10,11] も併せて示している。図 4-3 の凡例にある括弧内の数値は、推定成功率を求めるうえで許容する推定誤差を示している。±1.5° の場合については以降で述べる。

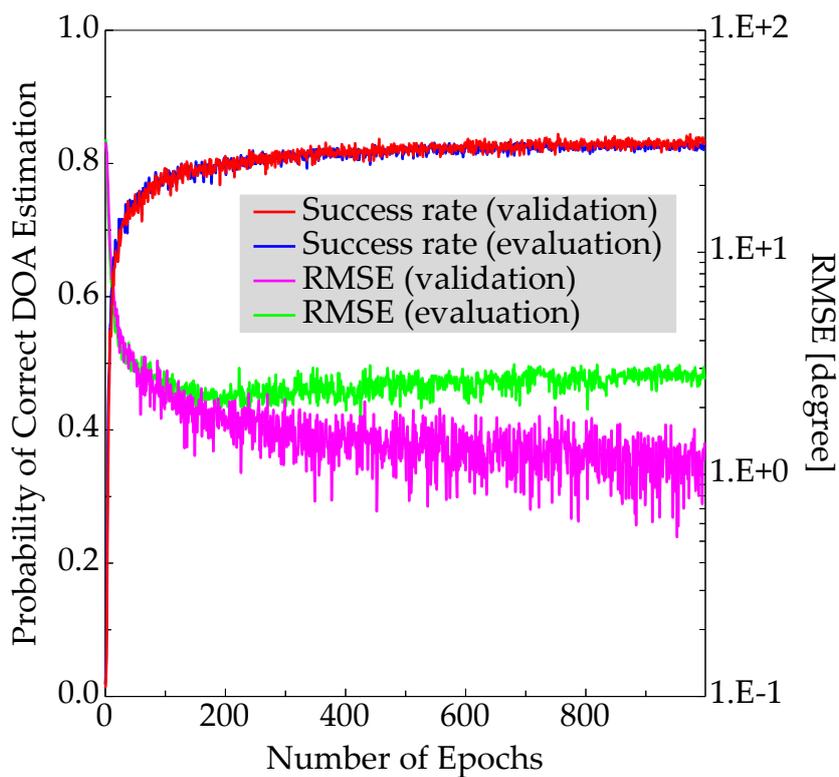


図 4-2 DNN A の学習曲線. 10,000 個のバリデーショndataまたは 100,000 個の推定データを使用して各エポック毎に得られた推定成功率と RMSE を示している (©2022 IEICE, [7] Fig. 4)

表 4-3 DNN A において最大推定成功率が得られたエポック数

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	996	948	992	960
	182	970	999	970	812
	242	916	964	975	878
	303	972	910	880	938
	363	989	899	755	971
	424	861	782	802	778
	484	952	928	775	744
	545	952	782	692	905
	605	739	782	821	689

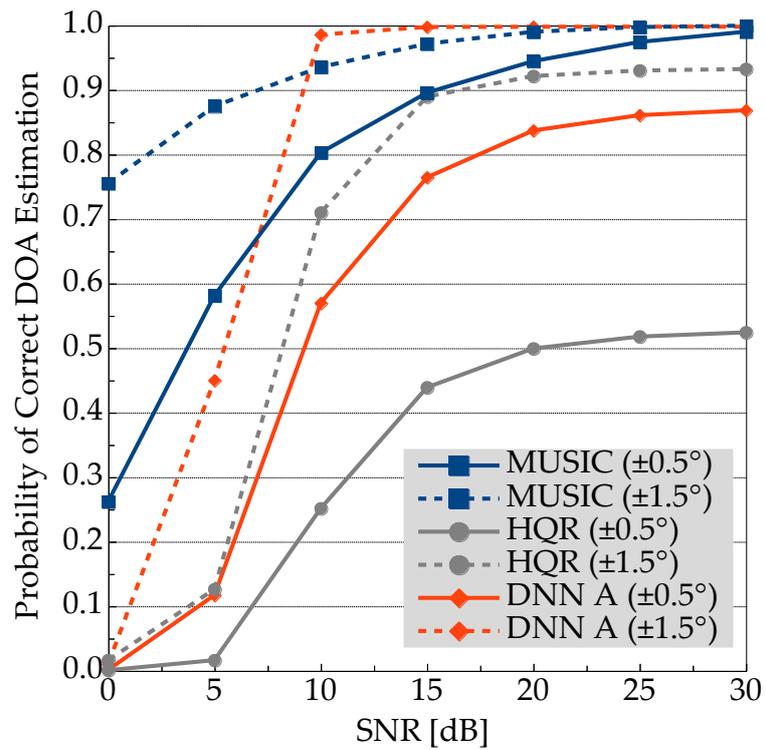


図 4-3 DNN A, Root-MUSIC, HQR の推定成功率の比較. 許容誤差を $\pm 1.5^\circ$ とした場合も併せて示している (©2022 IEICE, [7] Fig. 5)

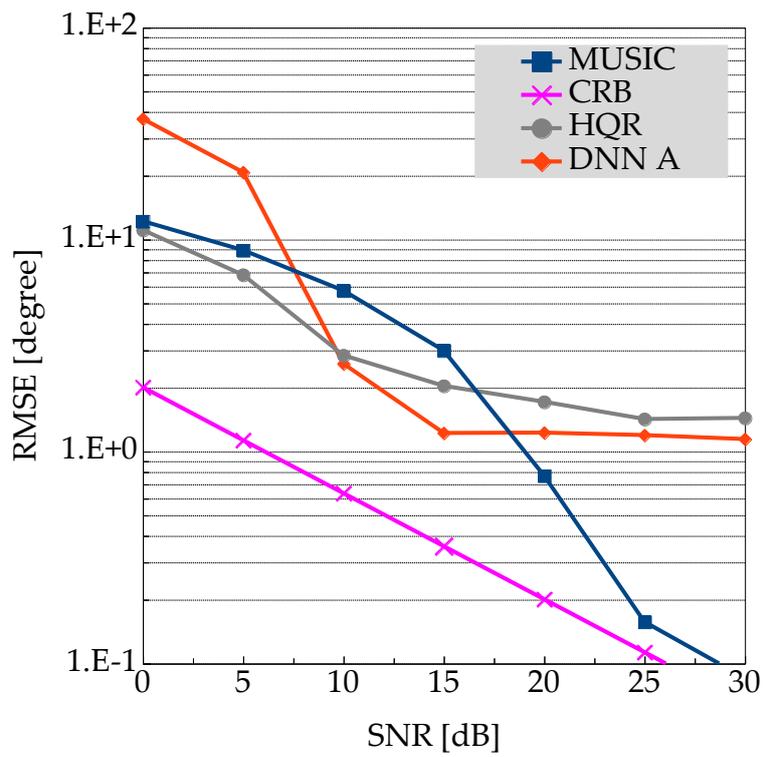


図 4-4 DNN A, Root-MUSIC, HQR の RMSE の比較. CRB も併せて示している
(©2022 IEICE, [7] Fig. 6)

推定時データの SNR が 20 dB のときの DNN A の推定成功率は、表 4-1 で示したように 83.7% である。SNR が 0 dB と 5 dB のときに推定成功率が著しく低いのは、訓練データの SNR 20 dB に最適化されたためであると考えられる。実数角度における訓練データの SNR と推定精度の関係と、低 SNR 時の推定精度改善については 5.3 節で検討している。

前述の通り、推定成功率は 2 波の推定値がどちらも最も近いユニット、すなわち誤差が $\pm 0.5^\circ$ 以内であった場合を成功として算出している。Root-MUSIC の許容推定誤差が $\pm 0.5^\circ$ のとき、SNR 20 dB で Root-MUSIC の推定成功率は 90% 以上となる。DNN A の RMSE は、SNR が 10 dB, 15 dB のとき Root-MUSIC のそれより小さいものの、約 1.2° で収束してしまい、SNR 20 dB 以上で再び Root-MUSIC の RMSE のほうが小さくなっている。

この性能差の原因を明らかにするため、DNN A が最近傍ユニットの推定に失敗したときの出力例を図 4-5 に示す。真の到来方向は -2.21° と 9.49° 、推定された到来方向は -2° と 10° である。この例では、 -2.21° から到来した信号に対しては、 -2° のユニットだけが強く反応して 1 を出力している一方で、 9.49° から到来した信号に対しては、 9° と 10° の 2 つのユニットの出力が共に大きく、かつ、 10° のユニットの出力がより大きくなっている。その結果、最近傍ユニットである 9° の推定に失敗している。このように、DNN の出力として設定したグリッドの境界上に信号が到来した場合に、隣接ユニットを到来方向と誤る場合があることが確認された。

図 4-3 には、許容誤差を $\pm 1.5^\circ$ としたときの推定成功率も併せて示している。最近傍ユニットに加えてその両隣のユニットを許容した場合、DNN A の推定成功率は大きく上昇し、SNR 15 dB 以上で約 100% となっている。これは、同じく許容誤差を $\pm 1.5^\circ$ としたときの Root-MUSIC の推定成功率よりも高い。したがって、このグリッド境界の問題が解決されれば、DNN は Root-MUSIC を超える推定成功率を実現できる可能性がある結論付けられる。

HQR の推定成功率は、許容誤差が $\pm 0.5^\circ$ 、 $\pm 1.5^\circ$ のどちらの場合においても Root-MUSIC や DNN A よりも低い。文献 [9] にあるように、HQR で MUSIC を超える性

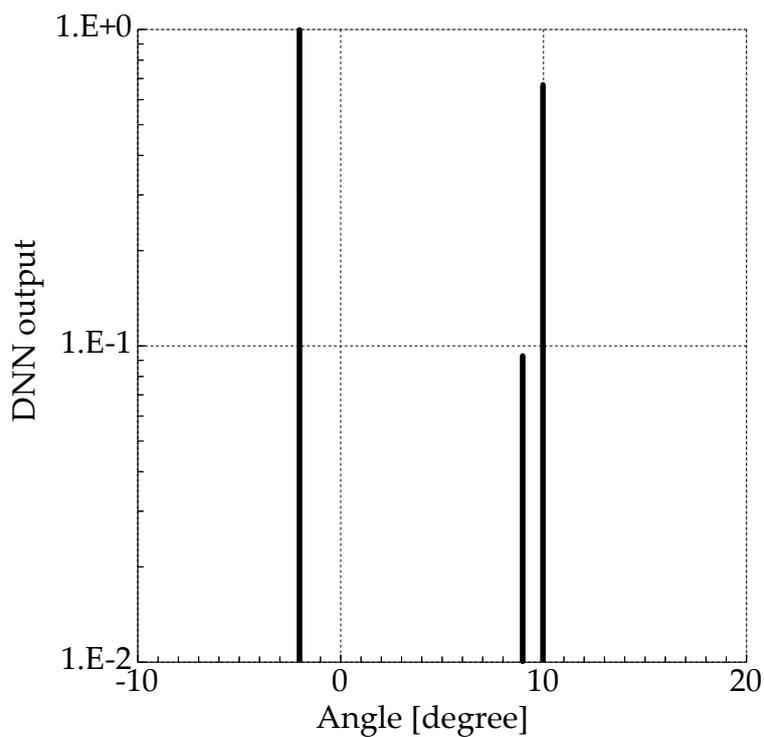


図 4-5 最近傍ユニットの推定に失敗したときの DNN A の出力例. 真の到来方向は -2.21° , 9.49° . 推定された到来方向は -2° , 10° (©2022 IEICE, [7] Fig. 7)

能を得られるのはマルチバンド信号を用いた場合である。本論文では、シングルバンド信号を用いた評価を行っているので、以降では Root-MUSIC を DNN との比較に用いる。

4.4.4 グリッド境界の問題を解決する提案手法

前節で、DNN の出力として設定した角度グリッドの境界上に信号が到来した場合に、境界を挟んで隣り合う 2 つのユニットの出力が大きくなり、最近傍グリッドの推定に失敗する可能性があることを確認した。この問題の解決策の 1 つとして、DNN を回帰モデルとして再構築することが挙げられる [12]。この場合、DNN は離散角度スペクトルではなく推定到来方向を直接出力するため、オフグリッド推定が行えるようになり、角度グリッドに起因する問題は発生しない。しかし、回帰モデルでは出力層のユニット数と到来波数を一致させる必要があるため、到来波数ごとに出力層の構造が異なる DNN を訓練しなければならないという問題がある。また、入力する受信データ相関行列には到来波のインデックス k 、つまり何番目の到来波であるかの情報は当然含まれておらず、推定到来方向の出力順も精度に影響しないが、出力順によって訓練結果が変わる可能性があるため、DNN の訓練は到来波数の増加に伴って複雑になる。もう 1 つの方法として、グリッド間隔を 1° より小さくすることが考えられる。しかし、この場合はグリッド間隔に反比例して各層のユニット数が増加し、訓練時間や難度が増加するだけでなく、グリッド境界の問題は依然として解決されていない。

そこで、図 4-6 に示すように、従来の角度グリッドをもつ DNN A と、そのグリッドと境界が重ならないよう 0.5° ずらしてグリッドをスタagger配置した DNN B を組み合わせる手法を提案する。グリッド間隔を狭めた場合と異なり、この手法ではどの角度に到来波が存在しても DNN A と DNN B のどちらか一方は必ず信頼度の高いグリッドの中央付近で推定が行える。また、DNN B は DNN A と独立、並列に訓練が可能であり、訓練にかかるコストも DNN A とほぼ等しい。推定時には 2 つの DNN の離散角度スペクトルを合成した結果からピークサーチによって到来方向を決定するものとした。DNN A の出力ユニットをすべて包含するよう、DNN B の出力ユニット

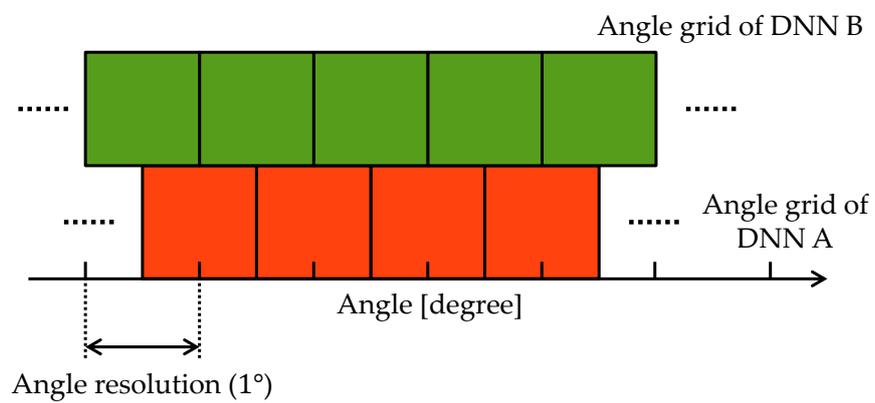


図 4-6 従来の角度グリッドをもつ DNN A と、グリッドを 0.5° ずらしてスタagger配置した DNN B (©2022 IEICE, [7] Fig. 8)

を 1° 間隔で 60.5° から 60.5° までと設定する。したがって、DNN B の出力ユニット数は 122 となる。

4.4.5 提案手法の評価

DNN B のパラメータを決定するため、DNN A と同様に 36 通りの層数とユニット数の DNN を訓練する。訓練データの到来波は -60.5° から 60.5° の範囲でランダムに到来するものとし、各層のユニット数は 122, 183, 244, 305, 366, 427, 488, 549, 610 の 9 パターンとする。これは出力層のユニット数である 122 の 1.0, 1.5, ..., 5.0 倍である。それ以外の条件は 4.4.1 節と同様である。訓練の結果得られた 36 通りの DNN を用いてランダム 2 波推定を行ったときの推定成功率と RMSE を表 4-4, 4-5 にそれぞれ示す。推定時データの SNR は 20 dB である。

最も高い推定成功率を示したのは中間層の層数が 3, ユニット数が 366 の DNN であった。そのときの推定成功率は 83.8% である。最も低い RMSE を示したのは中間層の層数が 5, ユニット数が 488 の DNN であった。そのときの RMSE は 0.976° である。これらは、表 4-4, 4-5 において太字で示されている。以降の評価では、最も高い推定成功率を示した中間層の層数が 3, ユニット数が 366 の DNN を DNN B として用いる。

DNN A と DNN B を単独で用いてランダム 2 波推定を行ったとき、および、これら 2 つの DNN を提案手法により組み合わせて推定を行ったときの推定成功率と RMSE を図 4-7, 4-8 にそれぞれ示す。参考として、Root-MUSIC を用いて推定を行ったときの推定成功率と RMSE も併せて示している。図 4-7, 4-8 の “MUSIC”, “DNN A” は図 4-3, 4-4 の “MUSIC ($\pm 0.5^\circ$)”, “DNN A ($\pm 0.5^\circ$)” と同一である。図 4-8 には CRB も示している。

加えて、図 4-7, 4-8 には角度グリッド間隔を DNN A, DNN B の半分である 0.5° とした 241 出力の DNN (DNN H) の推定成功率と RMSE もそれぞれ示している。DNN A, DNN B と同様に 36 通りの DNN を訓練した結果、最大の推定成功率を示したのは中間層の層数が 5, ユニット数が 603 の DNN であった。なお、このユニット数

表 4-4 DNN B の層数, ユニット数と推定成功率 (©2022 IEICE, [7] Table 3)

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	122	0.644	0.631	0.699	0.761
	183	0.689	0.769	0.758	0.761
	244	0.786	0.823	0.835	0.835
	305	0.809	0.830	0.836	0.834
	366	0.812	0.838	0.834	0.836
	427	0.821	0.831	0.830	0.836
	488	0.821	0.836	0.833	0.827
	549	0.822	0.833	0.829	0.830
	610	0.822	0.833	0.826	0.830

表 4-5 DNN B の層数, ユニット数と RMSE (©2022 IEICE, [7] Table 4)

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	122	11.14	7.846	7.041	5.073
	183	8.952	3.886	4.941	8.005
	244	4.545	2.131	1.544	5.474
	305	3.116	1.708	1.416	5.246
	366	2.760	1.595	4.119	3.269
	427	2.551	1.487	3.129	3.563
	488	2.719	1.399	1.885	0.976
	549	2.440	1.450	1.079	3.078
	610	2.487	1.402	1.347	2.849

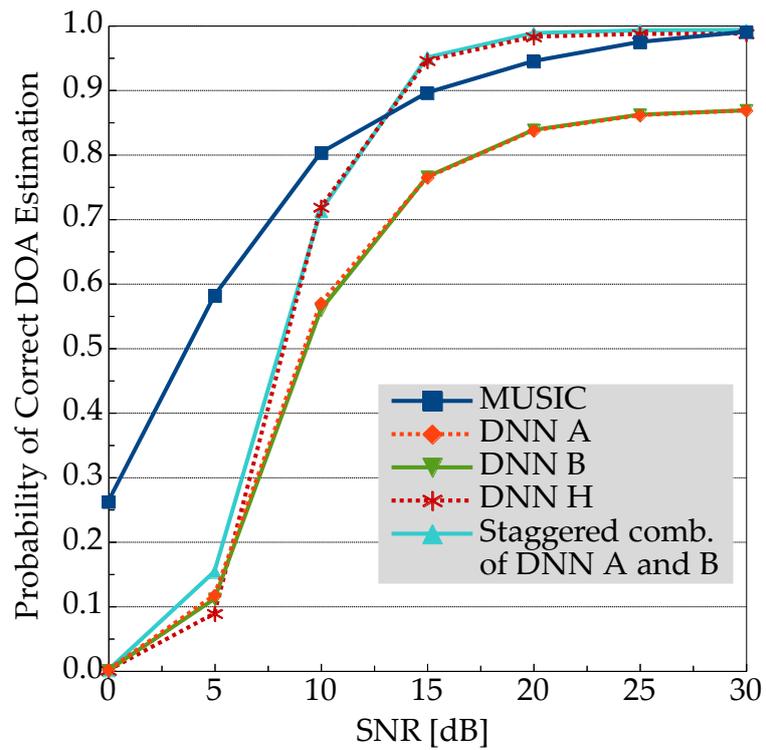


図 4-7 DNN A と DNN B をスタッガード配置により組み合わせた場合の推定成功率
(©2022 IEICE, [7] Fig. 9)

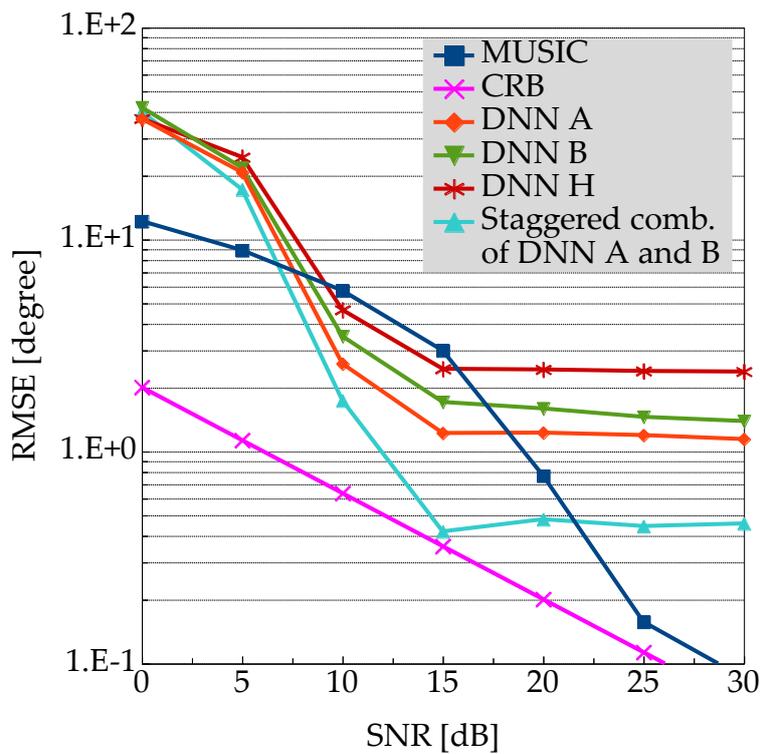


図 4-8 DNN A と DNN B をスタaggerド配置により組み合わせた場合の RMSE
 (©2022 IEICE, [7] Fig. 10)

は出力層のユニット数の 2.5 倍である。この DNN を DNN H として用いている。

図 4-7 では、DNN A と DNN B の推定成功率はほぼ等しく、重なっているが、DNN A と DNN B の RMSE は図 4-8 のように異なっている。これは、図 4-2 に見られるように、訓練途中の各エポックにおける推定成功率と RMSE はそれぞれ独立に振動しており、推定成功率が最も高いエポックで必ずしも RMSE も小さくなるとは限らないためである。

推定時データの SNR が 20 dB のときの DNN A, DNN B の推定成功率は、表 4-1, 4-4 で示したようにそれぞれ 83.7%, 83.8% である。Root-MUSIC の推定成功率と比較すると、どちらの DNN もすべての SNR において Root-MUSIC より推定成功率が低い。しかし、提案手法により 2 つの DNN を組み合わせて推定を行うと大きく改善し、SNR 15 dB 以上で Root-MUSIC を超え、20 dB 以上で 99% という高い推定成功率を示している。DNN H は、SNR が 10 dB 以上のとき、DNN A や DNN B よりも高い推定成功率を示しているものの、提案手法の推定成功率は DNN H よりもわずかに高い。また、RMSE も DNN A, DNN B, DNN H を単独で使用して推定した場合と比較して大幅に改善されている。提案手法は SNR が 15 dB のとき、RMSE が 0.4° になっており、これは CRB に近い特性である。高 SNR 時に推定に失敗する原因の大部分はグリッド境界の問題であったこと、この問題に対し提案手法は有効な解決策であり、グリッド間隔を狭めた DNN を訓練するよりも簡易に優れた性能が得られることが明らかとなった。

提案手法の成功例として、DNN A, DNN B の合成離散スペクトルを図 4-9 に示す。到来波の条件は図 4-5 と同じであり、真の到来方向は -2.21° と 9.49° である。DNN A は 9.49° の到来波に対して 10° のユニットが強く反応しており、最近傍ユニットである 9° の推定に失敗している。しかし、DNN B の 9.5° のユニットがより大きな値を出力している。ピークサーチにより -2° と 9.5° のユニットが選択されるため、提案手法ではどちらの到来波も最近傍ユニットの推定に成功する。

一方で、2 波が近接して到来した場合には推定に失敗する場合があることも確認された。図 4-8 において RMSE が SNR 15 dB から 30 dB にかけてわずかに振動してい

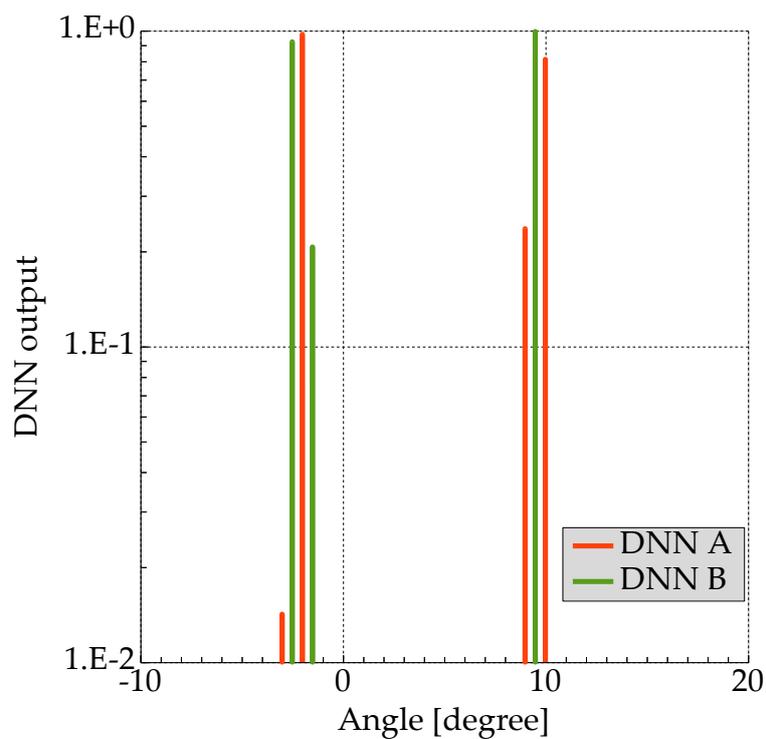


図 4-9 DNN A と DNN B の合成離散角度スペクトルの例. 真の到来方向は -2.21° , 9.49° . 提案手法により最近傍ユニットである -2° , 9.5° が推定される (©2022 IEICE, [7] Fig. 11)

るのは、このような近接波の分離に失敗して真の到来方向から離れたユニットが選択される試行がいくつかあったためである。推定成功率で評価した場合は $\pm 0.5^\circ$ 以上の誤差をすべて推定失敗と見なしているのに対し、RMSE では誤差の大きさも評価されるため、その影響が現れている。

4.4.6 近接波推定

ある特定の環境に特化した推定器を構築できる点は、DNN を用いた推定法の利点の 1 つである。近接波が到来した場合に見られる推定誤差を低減するため、3.6.5 節と同様に、2 波の到来角度差が 1° である、つまり $|\theta_1 - \theta_2| = 1^\circ$ である条件に適した DNN を設計する。

この 1° 近接条件を加えて 4.4.2 節、4.4.5 節の DNN A, DNN B と同様に訓練した結果得られた、それぞれ 36 通りの DNN を用いて 1° 近接波推定を行ったときの推定成功率を表 4-6, 4-7 に示す。推定時データの SNR は 20 dB である。表 4-6 より、DNN A と同じ角度グリッドをもつ 1° 近接波推定に特化した DNN C として、中間層の層数が 4、ユニット数が 424 の DNN を選択した。また、DNN B と同じく、DNN C と 0.5° ずれた角度グリッドをもつ 1° 近接波推定に特化した DNN D として、中間層の層数が 3、ユニット数が 305 の DNN を選択した。

DNN C, DNN D をそれぞれ単独で用いて 1° 近接波推定を行ったとき、および、これら 2 つの DNN をスタaggered 配置により組み合わせて推定を行ったときの推定成功率と RMSE をを図 4-10, 4-11 にそれぞれ示す。参考として、Root-MUSIC を用いて 1° 近接波推定を行ったときの推定成功率と RMSE も併せて示す。図 4-11 には CRB も併せて示している。

推定時データの SNR が 20 dB のときの DNN C, DNN D の推定成功率は、表 4-6, 4-7 で示したようにどちらも 96.3% である。SNR が 30 dB のときの推定成功率はそれぞれ 97.3%, 97.6% であり、47.9% の Root-MUSIC と比較して 2 倍の推定成功率を示している。SNR が 0 dB, 5 dB のとき、DNN C と DNN D の推定成功率が異なるのは、DNN D の層数、ユニット数が DNN C より少ないためである。いくつかのシミュ

表 4-6 DNN C の層数, ユニット数と推定成功率 (©2022 IEICE, [7] Table 5)

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	0.959	0.961	0.959	0.959
	182	0.962	0.963	0.961	0.961
	242	0.961	0.962	0.961	0.962
	303	0.961	0.961	0.960	0.959
	363	0.962	0.962	0.963	0.962
	424	0.960	0.962	0.963	0.960
	484	0.961	0.962	0.962	0.960
	545	0.961	0.962	0.962	0.962
	605	0.960	0.962	0.961	0.961

表 4-7 DNN D の層数, ユニット数と推定成功率 (©2022 IEICE, [7] Table 6)

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	122	0.957	0.958	0.961	0.957
	183	0.960	0.962	0.962	0.961
	244	0.958	0.961	0.961	0.962
	305	0.959	0.963	0.961	0.959
	366	0.962	0.959	0.959	0.961
	427	0.962	0.963	0.961	0.962
	488	0.962	0.961	0.962	0.959
	549	0.960	0.961	0.961	0.960
	610	0.962	0.962	0.962	0.959

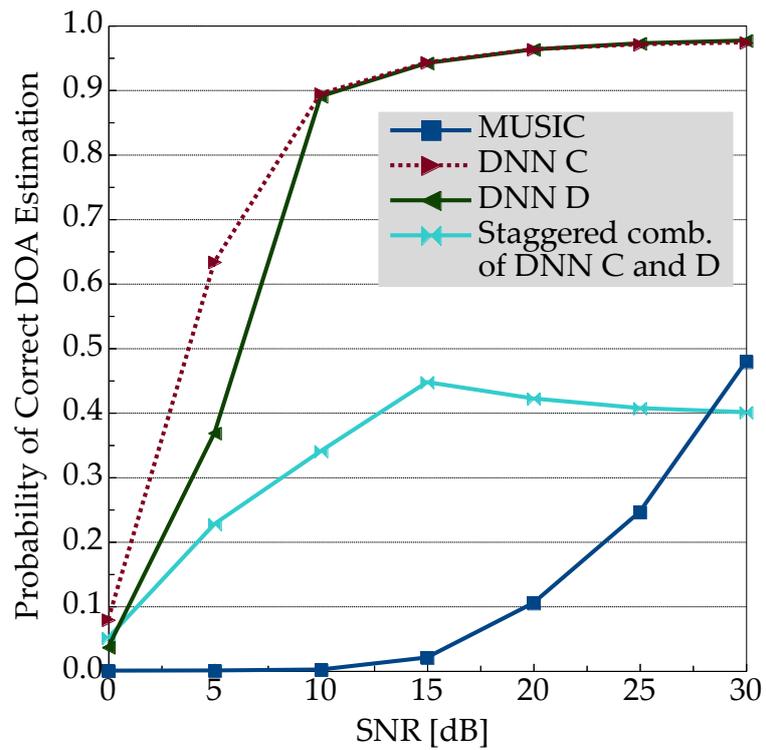


図 4-10 DNN C, DNN D とそのスタaggerド配置, Root-MUSIC の推定成功率の比較 (©2022 IEICE, [7] Fig. 12)

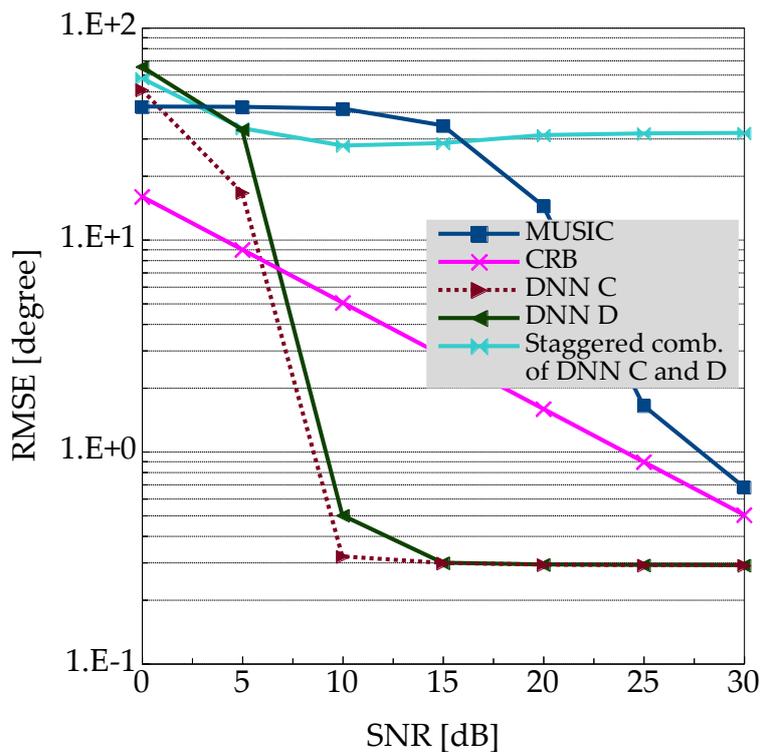


図 4-11 DNN C, DNN D とそのスタagger配置, Root-MUSIC の RMSE の比較. CRB も併せて示している (©2022 IEICE, [7] Fig. 13)

レーションにより、低 SNR 時の推定精度は層数とユニット数に大きく影響されることが分かっている。3.6.3 節で述べたように、訓練データの SNR を最適化することも重要であると考えられる。

DNN C, DNN D の RMSE は、SNR 15 dB 以上のとき、角度グリッドを 1° 間隔としていることによる下限（一様分布の量子化誤差 $1/\sqrt{12} \approx 0.289^\circ$ ）にほぼ等しい 0.291° に収束している。同 SNR 時における CRB よりも遥かに低い RMSE となっているのは、 1° 近接波しか到来しないという事前知識に基づいて DNN を訓練し、推定しているためである。実際、次節で述べるように、角度差の制約がない条件で DNN C, DNN D を使用すると推定精度が大きく劣化してしまう。しかし、従来法では推定が難しい環境に特化した DNN を構築可能であるという点は、他の推定法と補完的に利用して推定精度を改善できる可能性を示している。次節では、角度差の制約なしに訓練した DNN A, DNN B と理想的に組み合わせ推定を行った場合について、5.2 節では、 1° 近接波を検出する DNN を用いて組み合わせた場合について述べている。

一方で、DNN C と DNN D をスタaggerド配置により組み合わせた場合の推定成功率は、SNR が 30 dB のとき、Root-MUSIC よりも低い 40.0% となっている。近接波に対しては、 0.5° 間隔の合成角度スペクトルが真の到来方向近辺に 1 つのピークしか示さないことが多く見られた。したがって、近接波推定の場合はスタaggerド配置による組み合わせは適しておらず、DNN C または DNN D のどちらか一方を単独で用いたほうが良いと言える。

4.4.7 DNN A, DNN B, DNN C の理想的な組み合わせ

以上のように、DNN C と DNN D のスタaggerド配置による組み合わせは、 1° 近接波の推定においては適していない。その代わりに、DNN C または DNN D を単独で用いた場合はどちらも 97% 以上の推定成功率を達成し、Root-MUSIC を超える精度で推定が行えることを確認した。そこで、3.6.6 節と同様に、角度差の制約がないランダム 2 波推定において DNN A, DNN B, DNN C を理想的に組み合わせ推定した場合について検討する。ここでは、角度差の制約なしに訓練した DNN A, DNN B のスタaggerド配

置と、角度差の制約を設けて訓練した DNN C から得られた 2 通りの推定結果のうち、二乗誤差が小さかった一方を選択するものとする。

DNN A と DNN B を単独で用いてランダム 2 波推定を行ったとき、DNN A と DNN B のスタaggerド配置、DNN C、および、スタaggerド配置と DNN C を組み合わせて推定を行ったときの推定成功率と RMSE を図 4-12, 4-13 にそれぞれ示す。参考として、Root-MUSIC を用いて推定を行ったときの推定成功率と RMSE も併せて示している。図 4-13 には CRB も示している。図 4-12, 4-13 の“MUSIC”は図 4-3, 4-4 の“MUSIC ($\pm 0.5^\circ$)”と同一である。また、図 4-12, 4-13 の“Staggered (A and B)”は図 4-7, 4-8 の“Staggered comb. of DNN A and B”と同一である。

DNN C は 1° 近接条件下でしか訓練していないため、ランダム 2 波推定においては良い推定成功率を示していない。スタaggerド配置と DNN C を組み合わせた場合、推定成功率の改善はわずかであるものの、RMSE は大きく改善し、SNR 15 dB 以上でスタaggerド配置に見られた振動も解消されている。4.4.5 節で述べたように、近接波を分離できなかった場合、真の到来方向から遠く離れたユニットが選択されて RMSE が大きく劣化してしまうため、 $\pm 0.5^\circ$ 以上の誤差を失敗と見なす推定成功率よりも DNN C を組み合わせたことによる改善効果が表れている。スタaggerド配置による組み合わせでは推定に失敗してしまう条件で訓練した DNN をさらに組み合わせて推定を行うことで、ランダム 2 波推定の精度を改善できる可能性が示された。

なお、SNR が 10 から 20 dB のとき、スタaggerド配置と DNN C の組み合わせが CRB よりも低い RMSE を示しているのは、真の到来方向との二乗誤差に基づいて最適な一方を選択しているためである。 1° 近接波を検出する DNN を構築し、それに基づいて選択した場合については 5.2 節で検討している。

4.5 まとめ

本章では、線形アレーアンテナに等しい電力を有する無相関な狭帯域信号 2 波が、DNN の出力として設定した角度グリッドに拘束されないランダムな実数角度から到

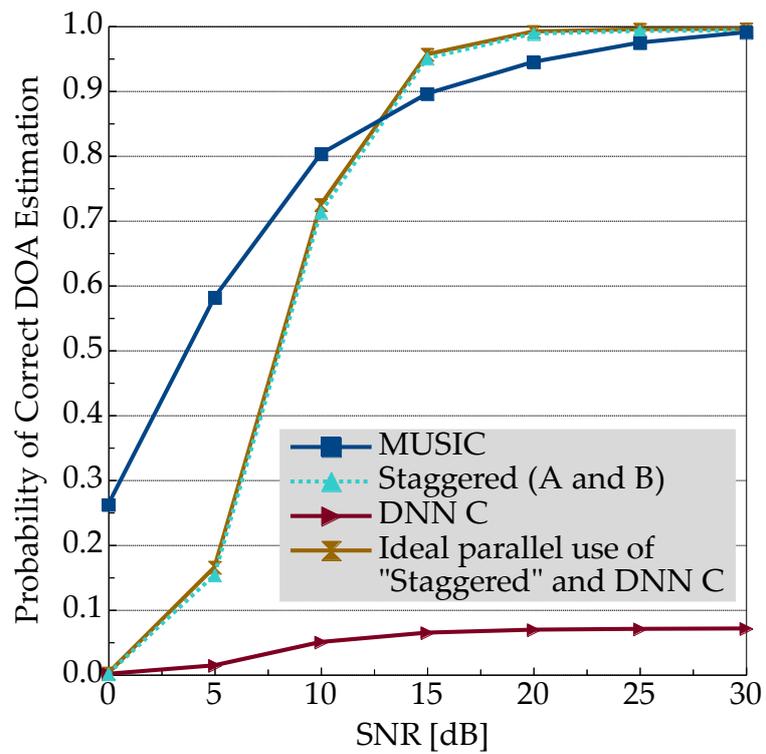


図 4-12 DNN A, DNN B のスタッガード配置と DNN C を理想的に組み合わせた場合の推定成功率 (©2022 IEICE, [7] Fig. 14)

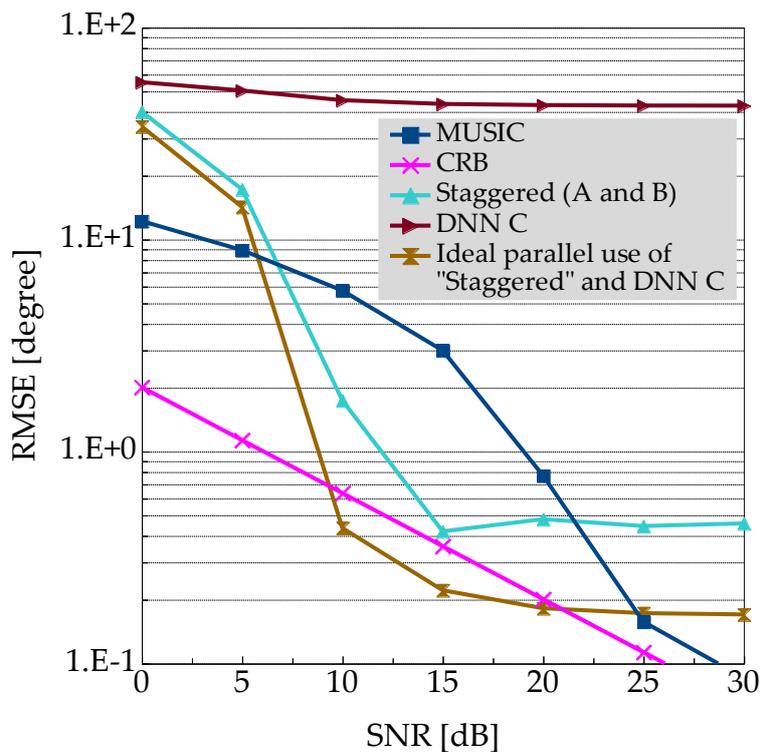


図 4-13 DNN A, DNN B のスタッガード配置と DNN C を理想的に組み合わせた場合の RMSE (©2022 IEICE, [7] Fig. 15)

来する条件において、DNN の到来方向推定性能を評価した。

ランダム 2 波推定では、DNN はどの SNR においても Root-MUSIC よりも低い推定成功率を示した。しかし、隣接ユニットへの誤りを許容した場合、すなわち、許容誤差を $\pm 1.5^\circ$ とした場合の推定成功率は、SNR 15 dB 以上で Root-MUSIC よりも高い約 100% となった。これは、DNN の出力として設定したグリッドの境界上に信号が到来した場合に、隣接ユニットを到来方向と誤る場合があるためであった。

この問題を解決するため、境界が重ならないようグリッドをスタagger配置した 2 つの DNN を組み合わせる手法を提案した。提案手法により、許容誤差 $\pm 0.5^\circ$ の推定成功率が SNR 15 dB 以上で Root-MUSIC を超え、20 dB 以上で 99% となった。高 SNR 時に推定に失敗する原因の大部分はグリッド境界の問題であったこと、この問題に対し提案手法は有効な解決策であることが明らかとなった。

1° 近接条件で DNN を訓練し、そのような厳しい到来条件であっても、97% を超える高い精度で推定が行えることを確認した。さらにこの DNN を、角度差の制約なしに訓練した 2 つの DNN のスタagger配置と組み合わせて推定を行うことで、ランダム 2 波推定の精度が向上することを確認した。

参考文献

- [1] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, X. Zheng, “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems,” arXiv:1603.04467v2, Mar. 2016.
- [2] S. Ioffe and C. Szegedy, “Batch normalization: accelerating deep network training by reducing internal covariate shift,” arXiv:1502.03167v3, Mar. 2015.
- [3] D. E. Rumelhart, G. E. Hinton and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986, DOI:10.1038/323533a0.
- [4] G. E. Hinton and R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol. 313, no. 5786, pp. 504–507, July 2006, DOI:10.1126/science.1127647.
- [5] N. Srivastava, G. E. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, “Dropout: A simple way to prevent neural networks from overfitting,” *Journal of Machine Learning Research*, vol. 15, no. 56, pp. 1929–1958, 2014.
- [6] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” arXiv:1412.6980v9, Jan. 2017.
- [7] Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, T. Sato, Y. Kishiyama, “Accuracy Improvement in DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E105-B, no. 5, May 2022 (Advance publication), DOI:10.1587/transcom.2021EBT0001.

-
- [8] B. D. Rao and K. V. S. Hari, "Performance analysis of Root-MUSIC," *IEEE Trans., Acoust., Speech, Signal Process.*, vol. ASSP-37, No.12, pp.1939–1949, 1989, DOI:10.1109/29.45540.
- [9] T. Terada, T. Nishimura, Y. Ogawa, T. Ohgane, and H. Yamada, "DOA estimation for multi-band signal sources using compressed sensing techniques with Khatri-Rao processing," *IEICE Trans. Commun.*, vol. E97-B, no. 10, pp. 2110–2117, Oct. 2014, DOI:10.1587/transcom.E97.B.2110.
- [10] P. Stoica and A. Nehorai, "MUSIC, maximum likelihood, and Cramer-Rao bound," *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 37, no. 5, pp. 720–741, May 1989, DOI:10.1109/29.17564.
- [11] P. Stoica and A. Nehorai, "MUSIC, maximum likelihood, and Cramer-Rao bound: further results and comparisons," *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 38, no. 12, pp. 2140–2150, Dec. 1990, DOI:10.1109/29.61541.
- [12] Y. Cao, T. Lv, Z. Lin, P. Huang and F. Lin, "Complex ResNet aided DoA estimation for near-field MIMO systems," *IEEE Trans. Veh. Technol.*, vol. 69, no. 10, pp. 11139–11151, Oct. 2020, DOI:10.1109/TVT.2020.3007894.

5 推定精度改善手法の検討

5.1 はじめに

3.6.6 節, 4.4.7 節では, 1° 近接条件で訓練した DNN と, 角度差の制約なしに訓練した DNN を組み合わせて推定を行うことで, 角度差の制約なしに訓練した DNN を単独で用いた場合よりも推定精度が向上することを確認した. しかし, この組み合わせは理想的に行われており, 具体的な選択手法については検討していない.

3.6.3 節では, SNR を種々のパターンで変化させながら DNN を訓練し, 訓練データの SNR によって推定精度が変化することを述べた. 高 SNR 一定のデータで訓練した DNN が高 SNR 時に良い特性を示したため, 第 4 章では簡単のため訓練データの SNR を 20 dB で一定とした. しかし, その結果低 SNR 時の推定成功率が低下したため, 実数角度においても訓練データの SNR を検討する余地がある.

本章では, 推定精度の更なる向上のため, 引き続き機械学習向けのオープンソースライブラリである TensorFlow [1] を用いて, 異なる条件で訓練した複数の DNN を組み合わせる具体的な手法を検討する. 初めに, 到来角度差が 1° であったかを検出する DNN を構築し, 1° 近接条件で訓練した DNN と, 到来角度差の制約なしに訓練した DNN を切り替えて推定する手法を検討する. 次に, 異なる SNR で訓練した複数の DNN の推定精度を比較する. SNR を推定する DNN を構築し, これらの DNN を切り替えて推定する手法について検討する.

5.2 1° 近接波を検出する DNN を用いた組み合わせ

4.4.7 節では, 角度差の制約なしに訓練した DNN A, DNN B のスタaggered配置と, 角度差の制約を設けて訓練した DNN C から得られた 2 通りの推定結果のうち, 二乗誤差が小さかった一方を理想的に選択した. 本節では, 到来方向推定に用いてきたものと同じ式 (4-5) の入力ベクトルから, 到来波が 1° 近接波であったかを検出する DNN P を構築し, その結果に基づいてスタaggered配置または DNN C どちらの推定

結果を採用するかを決定する手法を検討する。

5.2.1 1° 近接波を検出する DNN の訓練

5 素子半波長等間隔線形アレーアンテナに、等しい電力を有する狭帯域無相関波 2 波が、 -60° から 60° の範囲でランダムに到来するモデルにおいて、訓練および推定シミュレーションを行う。スナップショット数は 100 とし、この 100 個のデータから相関行列を計算する。

DNN P への入力は DNN A, DNN B, DNN C への入力と同一であり、入力ユニット数は 25 である。DNN P の出力は、到来波が 1° 近接波であった場合に 1 を出力するユニットと、それ以外の場合に 1 を出力するユニットの 2 つで構成する。中間層の層数は 2 から 5 の 4 通り、ユニット数は DNN A と同じ 121, 182, 242, 303, 363, 424, 484, 545, 605 の 9 通りを考える。したがって、36 通りの DNN を訓練する。中間層のユニットの活性化関数は DNN A, DNN B, DNN C と同じ正規化線形関数とする。出力層のユニットの活性化関数は、出力値が one-hot であるという設計に従い、ソフトマックス関数

$$z_j^{(M)} = \frac{\exp(u_j^{(M)})}{\sum_{j=1}^J \exp(u_j^{(M)})}. \quad (5-1)$$

とする。これは主にクラス分類で用いられる非線形関数である [2]。この関数では、それぞれのユニットは 0 から 1 の範囲の値を出力するが、全ユニットの出力値の合計が 1 になるよう正規化される。

DNN A, DNN B, DNN C と同じく、訓練は誤差逆伝播法 [3] を用いたバッチ学習により行う。また、最適化手法として、学習率を過去の勾配から適応的に決定する Adam [4] と、各ユニットへの入力をバッチ単位で平均 0, 分散 1 に正規化する Batch Normalization [5] を適用する。エポック数は最大 999, バッチサイズは 128 とする。訓練データは 200,000 個, バリデーションデータは 10,000 個とする。ただし、ランダム 2 波推定において 1° 近接条件となる割合は低いため、それぞれのデータセットのうち、半分は角度差の制約なしに生成したデータ, もう半分は 1° 近接条件で生成した

データとなるよう配分した。SNR は 0 dB から 30 dB の範囲でランダムとした。

表 5-1 は、訓練の結果得られた 36 通りの DNN を用いて 1° 近接波の検出を行ったときの検出成功率を示している。推定時データの SNR は 0 dB から 30 dB の範囲でランダムであり、100,000 回の試行のうち、半分は 1° 近接波、もう半分はランダム 2 波である。最も高い検出成功率を示したのは中間層の層数が 5、ユニット数が 182 の DNN であった。このときの検出成功率は 98.4% である。以降では、この DNN を DNN P として用いる。

5.2.2 1° 近接波の検出結果に基づく DNN 選択

DNN P の 1° 近接波検出結果に基づいて、DNN A、DNN B とスタaggerド配置または DNN C を切り替えてランダム 2 波推定を行ったときの推定成功率と RMSE を図 5-1、5-2 にそれぞれ示す。参考として、Root-MUSIC [6] の推定成功率と RMSE も併せて示している。図 5-2 には CRB (Cramér-Rao Bound) [7, 8] も併せて示している。これらの図における“MUSIC”, “Staggered (A and B)”, “Ideal parallel use of “Staggered” and DNN C”, “CRB” は、図 4-12, 4-13 に示したものと同一である。

DNN P の検出結果に基づいてスタaggerド配置と DNN C を切り替えた場合の推定成功率は、スタaggerド配置を単独で使用した場合と比較して、どの SNR においてもわずかに低下している。これは、1° 近接波の検出で偽陽性が発生した場合に、1° 近接波に特化した DNN C をランダム 2 波推定に適用してしまうためである。しかし、RMSE はスタaggerド配置を単独で使用した場合と比較して大きく改善し、SNR が 25 dB と 30 dB のときは、真の到来方向との二乗誤差に基づく理想的な組み合わせに近い RMSE となっている。推定成功率の劣化については、スタaggerド配置と DNN C を切り替える到来角度差の閾値や、DNN P の出力層の設計などについて検討を進めることで抑えられると期待される。

表 5-1 DNN P の層数, ユニット数と 1° 近接波の検出成功率

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	0.981	0.982	0.982	0.983
	182	0.981	0.981	0.982	0.984
	242	0.980	0.982	0.981	0.983
	303	0.980	0.981	0.982	0.983
	363	0.980	0.982	0.981	0.983
	424	0.981	0.981	0.981	0.983
	484	0.981	0.981	0.981	0.982
	545	0.980	0.981	0.979	0.983
	605	0.980	0.981	0.980	0.983

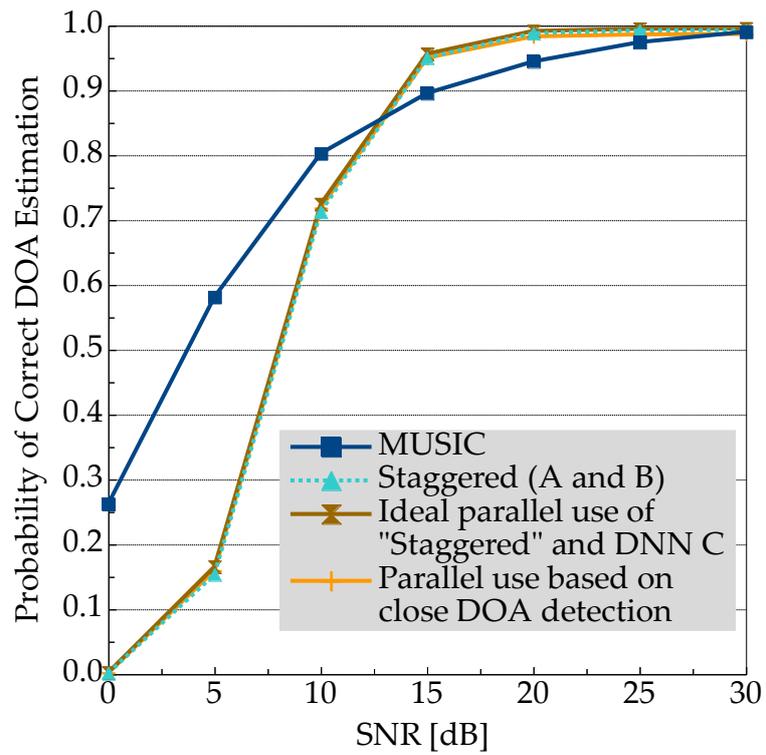


図 5-1 1° 近接波の検出結果に基づいて DNN A, DNN B のスタaggerド配置と DNN C を切り替えた場合の推定成功率

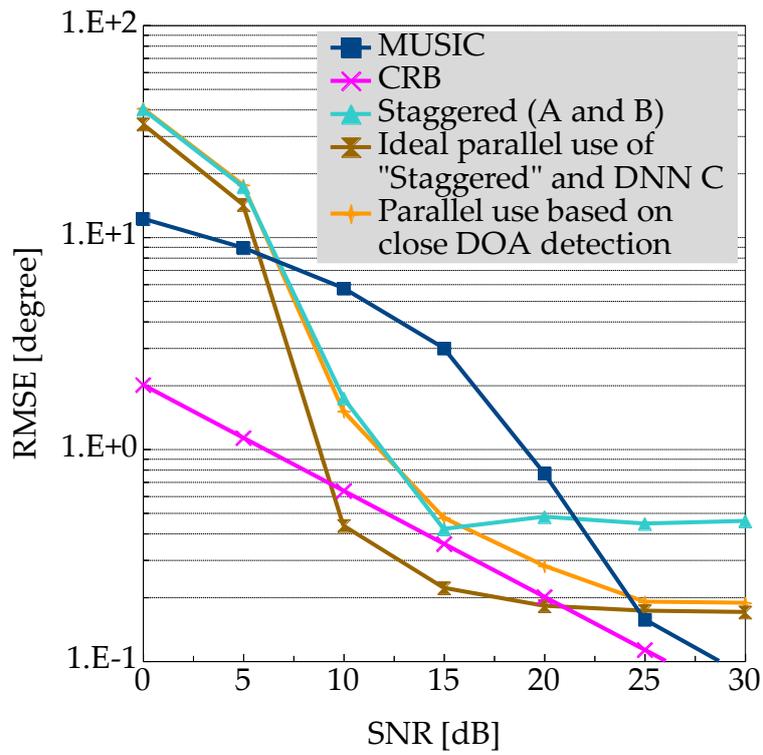


図 5-2 1° 近接波の検出結果に基づいて DNN A, DNN B のスタaggerド配置と DNN C を切り替えた場合の RMSE

5.3 SNR を推定する DNN を用いた組み合わせ

3.6.3 節では、訓練データの SNR を種々のパターンで変化させた結果、高 SNR 一定のデータで訓練した DNN が高 SNR 時の推定に最も適していること、SNR がランダムに変化するデータで訓練した DNN は幅広い SNR に適したものになることが確認された。また、4.4.3 節では、訓練データの SNR を 20 dB 一定とした結果、低 SNR 時の推定精度が劣化することが確認された。本節では、実数角度における訓練データの SNR を変化させた場合の推定精度の検討を行う。また、到来方向推定に用いてきたものと同じ式 (4-5) の入力ベクトルから SNR を推定する DNN S を構築し、その結果に基づいて異なる SNR で訓練した DNN を切り替えて推定する手法について検討する。

5.3.1 訓練データの SNR と DNN パラメータ

DNN の訓練は、DNN A と同様に行う。つまり、入力ユニット数は 25、出力ユニット数は 121 であり、中間層の層数は 2 から 5 の 4 通り、ユニット数は 121, 182, 242, 303, 363, 424, 484, 545, 605 の 9 通りである。また、中間層のユニットの活性化関数は正規化線形関数、出力層のユニットの活性化関数は正規化線形関数である。訓練データは 200,000 個、バリデーションデータは 10,000 個であり、到来方向は -60° から 60° の範囲でランダムである。ただし、訓練データの SNR は 0, 5, ..., 30 dB に固定した場合と、0 dB から 30 dB の範囲でランダムとした場合の合計 8 通りを考える。したがって、本節では、SNR が異なる 8 通りのデータをそれぞれ用いて、中間層の層数とユニット数が異なる 36 通りの DNN を訓練する。

表 5-2 は、訓練の結果得られた 288 通りの DNN のうち、SNR が 30 dB 一定のデータセットを用いて訓練した 36 通りの DNN を用いてランダム 2 波推定を行ったときの推定成功率を示している。最も高い推定成功率を示したのは中間層の層数が 4、ユニット数が 363 の DNN であった。このときの推定成功率は 87.9% であり、表 5-2 において太字で示している。以降では、この DNN を“30 dB”と表すものとする。

同様に、残りの 7 通りのデータセットを用いて訓練した DNN のうち、最も高い推

表 5-2 SNR 30 dB 一定のデータセットで訓練した DNN の層数, ユニット数と推定成功率

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	0.635	0.738	0.733	0.761
	182	0.762	0.814	0.797	0.787
	242	0.818	0.854	0.869	0.842
	303	0.840	0.871	0.869	0.866
	363	0.848	0.873	0.879	0.874
	424	0.851	0.875	0.875	0.876
	484	0.853	0.873	0.877	0.871
	545	0.855	0.873	0.875	0.873
	605	0.857	0.870	0.876	0.872

定成功率を示した DNN の層数とユニット数を表 5-3 に示す。

5.3.2 推定精度の比較

訓練の結果得られた 8 通りの DNN を用いてランダム 2 波推定を行ったときの推定成功率と RMSE を図 5-3, 5-4 にそれぞれ示す。なお、これらのグラフの横軸は推定時データの SNR を表している。

推定時の SNR が 0 dB の場合に注目すると、“0 dB” のデータセットで訓練した DNN が最も高い推定成功率を示している。その他の SNR においても同様の特徴が見られる。つまり、推定時と同じ SNR で訓練した DNN が、その SNR において最も高い推定成功率を示している。“0 dB” と “5 dB” のデータセットで訓練した DNN の推定成功率が高 SNR 時に低下しているのは、雑音に埋もれている相関行列の特徴をうまく捉えることができず、雑音が含まれていない場合に対応できなかったためと考えられる。“random” のデータセットで訓練した DNN は、低 SNR 時には比較的良好な推定成功率を示しているものの、高 SNR 時の推定成功率は “25 dB” および “30 dB” のデータセットで訓練した DNN に劣る。これらの結果は、広範囲の SNR で高い推定成功率を示す DNN を訓練することは困難であることを示している。

図 5-4 に示した RMSE においても同様の傾向が見られるが、厳密には異なる点がいくつかある。低 SNR 時に “random” のデータセットで訓練した DNN が他の DNN より良い RMSE を示しているほか、高 SNR 時に “10 dB”, “15 dB” などのデータセットで訓練した DNN の RMSE が振動している。これは、RMSE が最小になるようにではなく、推定成功率が最大になるように DNN のパラメータを選択したためであると考えられる。

5.3.3 SNR を推定する DNN の訓練

前節では、広範囲の SNR で動作する DNN を訓練することは困難であることを確認した。一方で、ある特定の SNR で良好に動作する DNN を訓練することは可能である。したがって、到来波の SNR が分かれば、それに合わせて DNN を選択することで

表 5-3 訓練データの SNR と最大推定成功率が得られた DNN の層数, ユニット数

SNR of training data set	No. of intermediate layers	No. of units
(i) 0 dB	5	605
(ii) 5 dB	3	303
(iii) 10 dB	3	303
(iv) 15 dB	3	424
(v) 20 dB	4	303
(vi) 25 dB	3	363
(vii) 30 dB	4	363
(viii) random	3	303

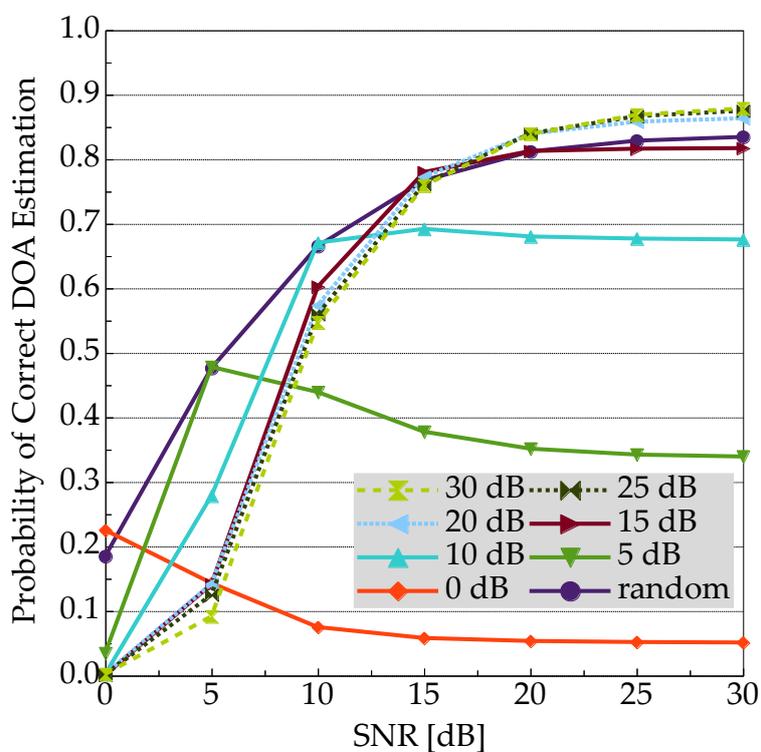


図 5-3 異なる SNR で訓練した DNN の推定成功率

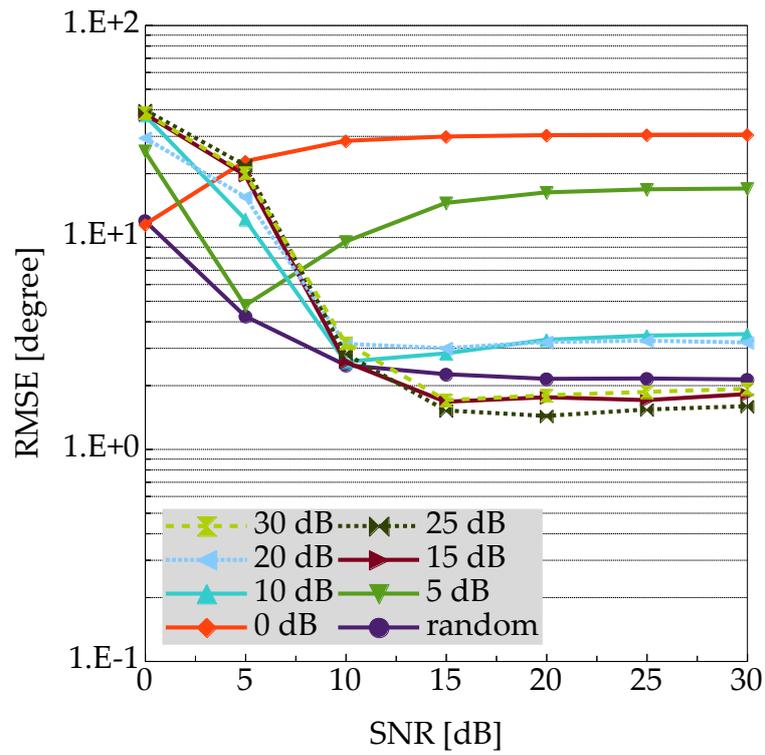


図 5-4 異なる SNR で訓練した DNN の RMSE

推定精度の改善が見込める。受信信号が未知であっても到来方向推定は行えるが、そのような場合に受信信号から信号成分と雑音成分を推定することは困難である。そこで本節では、到来波に関する事前知識なしに、到来方向推定に用いてきたものと同じ式 (4-5) の入力ベクトルから SNR を推定する DNN S を構築する。

DNN S への入力はいままで検討した DNN への入力と同一であり、入力ユニット数は 25 である。DNN S の出力は、SNR が 0, 5, ..., 30 dB であった場合にそれぞれ 1 を出力する 7 つのユニットで構成する。中間層の層数は 2 から 5 の 4 通り、ユニット数は DNN A と同じ 121, 182, 242, 303, 363, 424, 484, 545, 605 の 9 通りを考える。したがって、36 通りの DNN を訓練する。中間層のユニットの活性化関数はこれまで検討した DNN と同じ正規化線形関数とする。出力層のユニットの活性化関数は、出力値が one-hot であるという設計に従い、DNN P と同じソフトマックス関数とする。

訓練データは 200,000 個、バリデーションデータは 10,000 個である。到来方向は -60° から 60° の範囲でランダム、SNR も 0 dB から 30 dB の範囲でランダムとする。

表 5-4 は、訓練の結果得られた 36 通りの DNN を用いて SNR 推定を行ったときの推定成功率を示している。推定成功率は、真の SNR に最も近いユニットが選択された場合を成功として算出している。すなわち、許容誤差は ± 2.5 dB である。どの層数、ユニット数でも約 72% 以上の推定成功率が得られている。最も高い推定成功率を示したのは中間層の層数が 3、ユニット数が 182 の DNN であった。このときの推定成功率は 78.8% である。以降では、この DNN を DNN P として用いる。

図 5-5 は、DNN S によって推定された SNR と真の SNR を示している。真の SNR が 15 dB 以下のときは、グリッド境界の問題はあるものの、ほぼ ± 2.5 dB 以内の誤差で推定が行えていることがわかる。一方で、雑音電力は SNR [dB] に対して指数関数的に減少するため、真の SNR が 20 dB, 25 dB, 30 dB の場合はほぼ区別できていない。それでも、真の SNR が 20 dB 以上のときに推定 SNR が 10 dB 以下になることはないため、少なくとも SNR が 20 dB 以上であるという推定結果を得ることはできる。

表 5-4 DNN S の層数, ユニット数と SNR 推定成功率

		Number of intermediate layers			
		2	3	4	5
Number of units per intermediate layer	121	0.755	0.750	0.744	0.751
	182	0.763	0.788	0.734	0.758
	242	0.753	0.734	0.746	0.759
	303	0.747	0.730	0.767	0.742
	363	0.730	0.715	0.737	0.744
	424	0.718	0.727	0.735	0.762
	484	0.726	0.721	0.720	0.761
	545	0.724	0.734	0.723	0.721
	605	0.728	0.726	0.754	0.755

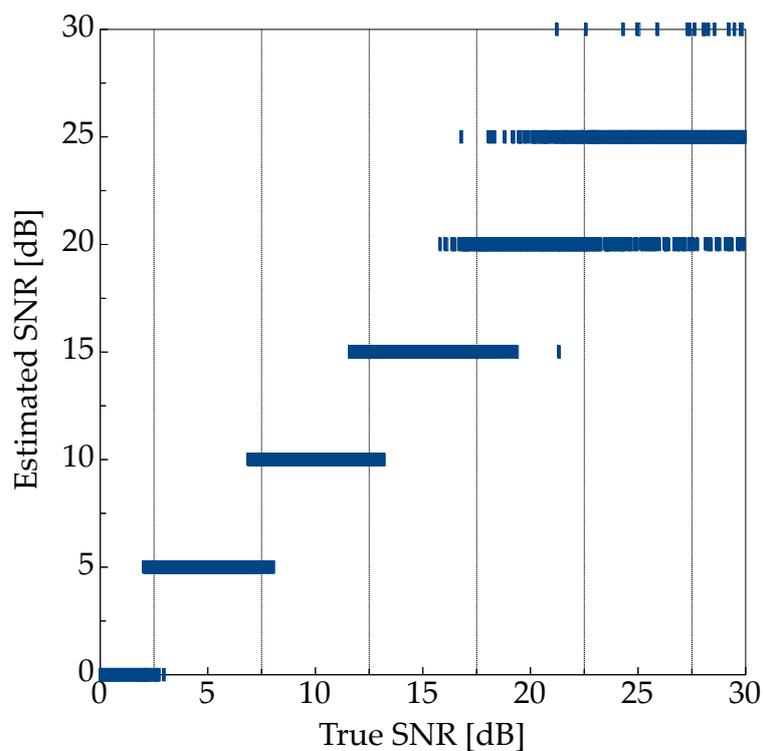


図 5-5 DNN S によって推定された SNR と真の SNR

5.3.4 SNR の推定結果に基づく DNN 選択

最後に、DNN S により推定された SNR に基づいて、到来方向推定を行う DNN を選択した場合について検討する。ここでは、実装時の負荷も考慮して、同一の DNN 構造でウェイトのみを切り替えるものとして評価を行う。SNR が 30 dB の時に最も高い到来方向推定成功率を得られるよう、SNR に関わらず中間層の層数を 4、ユニット数を 363 に固定する。

到来方向推定は、“0 dB”，“5 dB”，“10 dB”，“15 dB”，“30 dB” のデータセットで訓練した 5 つの DNN から 1 つを選択して行う。“30 dB” のデータセットで訓練した DNN は、推定された SNR が 20 dB 以上であった場合に使用する。“20 dB”，“25 dB” のデータセットで訓練した DNN を使用しないのは、真の SNR が 20 dB 以上の場合は DNN S の SNR 推定成功率が低く、また、高 SNR 時には“30 dB” のデータセットで訓練した DNN が良好に動作するためである。図 5-6(a), 5-6(b) は、5.3.2 節と本節で述べている到来方向推定のブロック図をそれぞれ示している。

DNN S による SNR 推定結果に基づいて DNN のウェイトを切り替えてランダム 2 波推定を行ったときの到来方向推定成功率と RMSE を図 5-7, 5-8 にそれぞれ示す。参考として、図 5-3, 5-4 に示した“30 dB”，“random” のデータセットで訓練した DNN の推定成功率と RMSE も併せて示している。高 SNR 時の推定成功率を維持しつつ、低 SNR 時の推定成功率が“30 dB” のデータセットで訓練した DNN と比較して大きく改善していることがわかる。SNR 推定に基づく DNN 選択は、広範囲の SNR で動作する DNN を構築するための有効な手法であることが示された。

図 5-8 に示した、DNN 選択を行った場合の RMSE には僅かな劣化が見られる。これは、到来方向推定用の DNN は RMSE について最適化されておらず、また DNN 構造も SNR によらず固定しているためである。

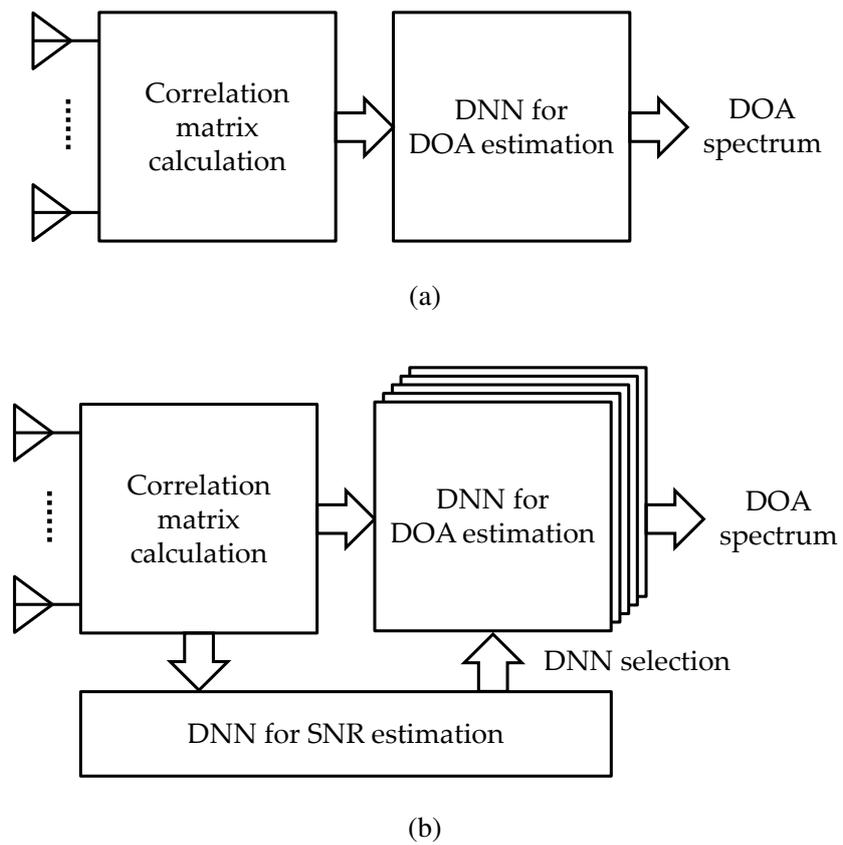


図 5-6 到来方向推定のブロック図. (a) 単一の DNN を用いる場合. (b) SNR 推定結果に基づいて DNN を切り替える場合

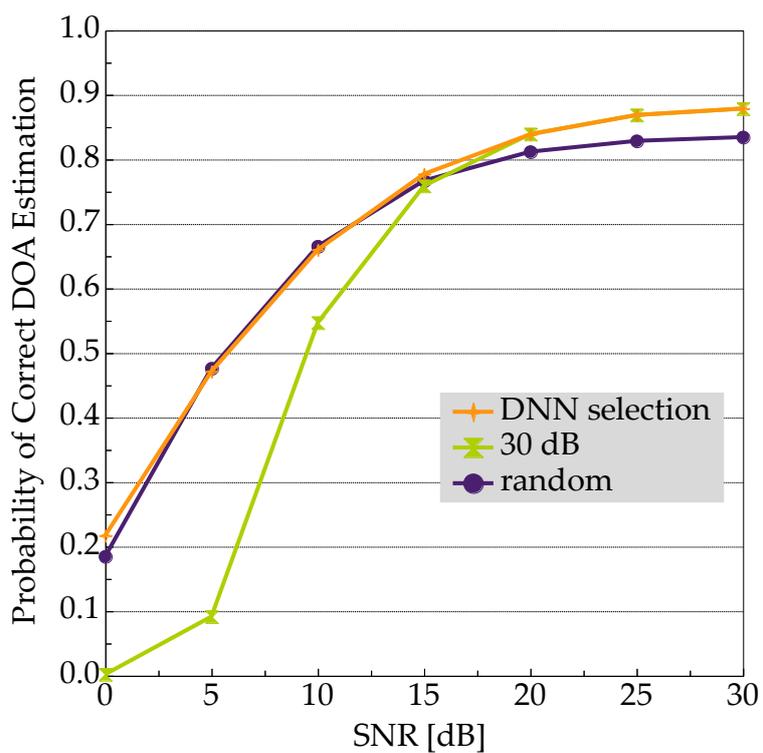


図 5-7 SNR 推定結果に基づいて DNN のウェイトを切り替えた場合の推定成功率

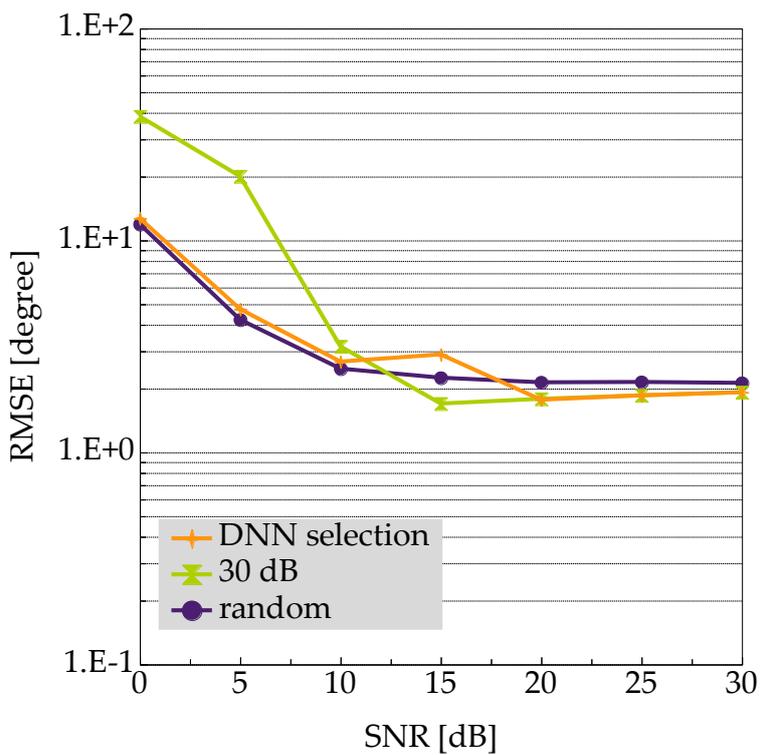


図 5-8 SNR 推定結果に基づいて DNN のウェイトを切り替えた場合の RMSE

5.4 まとめ

本章では、具体的な組み合わせ手法の検討と推定精度の更なる向上のため、到来角度差が 1° であったかを検出する DNN を構築し、その結果に基づいてスタaggerド配置または DNN C どちらの推定結果を採用するかを決定する手法と、SNR を推定する DNN を構築し、その結果に基づいて異なる SNR で訓練した DNN を切り替えて推定する手法を検討した。

1° 近接波を検出する DNN P により、到来角度差に関する事前知識がなくとも、スタaggerド配置または DNN C を選択可能となった。スタaggerド配置を単独で使った場合と比較して RMSE が大きく改善し、SNR が 25 dB と 30 dB のときは、真の到来方向との二乗誤差に基づく理想的な組み合わせに近い RMSE が得られた。

SNR が異なるデータセットで DNN を訓練した結果、推定時と同じ SNR で訓練した DNN が、その SNR において最も高い推定成功率を示すことが確認された。これは、広範囲の SNR で高い推定成功率を示す DNN を訓練することは困難であることを示している。しかし、到来波の SNR に関する事前知識がなくとも、SNR を推定する DNN S に基づいて、異なる SNR で訓練した DNN から最適なものを選択できることを示した。これにより、高 SNR 時の推定成功率を維持しつつ、低 SNR 時の推定成功率が大幅に改善した。SNR 推定に基づく DNN 選択は、広範囲の SNR で動作する DNN を構築するための有効な手法であることが示された。

参考文献

- [1] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, X. Zheng, “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems,” arXiv:1603.04467v2, Mar. 2016.
- [2] 岡谷貴之, “深層学習,” 講談社, 東京, 2015.
- [3] D. E. Rumelhart, G. E. Hinton and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986, DOI:10.1038/323533a0.
- [4] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” arXiv:1412.6980v9, Jan. 2017.
- [5] S. Ioffe and C. Szegedy, “Batch normalization: accelerating deep network training by reducing internal covariate shift,” arXiv:1502.03167v3, Mar. 2015.
- [6] B. D. Rao and K. V. S. Hari, “Performance analysis of Root-MUSIC,” *IEEE Trans., Acoust., Speech, Signal Process.*, vol. ASSP-37, No.12, pp.1939–1949, 1989, DOI:10.1109/29.45540.
- [7] P. Stoica and A. Nehorai, “MUSIC, maximum likelihood, and Cramer-Rao bound,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 37, no. 5, pp. 720–741, May 1989, DOI:10.1109/29.17564.
- [8] P. Stoica and A. Nehorai, “MUSIC, maximum likelihood, and Cramer-Rao bound: further results and comparisons,” *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 38, no. 12, pp. 2140–2150, Dec. 1990, DOI:10.1109/29.61541.

6 結論

本論文では、深層学習を用いた電波の到来方向推定について、計算機シミュレーションによりその性能評価を行った。

第1章は序論である。研究の背景と目的、本論文の構成について述べた。

第2章では、アレーアンテナの定式化と、これを用いた代表的な到来方向推定法である MUSIC とその派生手法である Root-MUSIC について説明した。MUSIC や Root-MUSIC は、受信データ相関行列の固有空間が、互いに直交補空間である信号部分空間と雑音部分空間に分割できることを利用し、ヌル走査により到来方向を推定する手法である。これらの手法が、メインローブ走査により到来方向推定を行う beamformer 法や Capon 法と比較して高い分解能をもつことを示した。また、ある SNR やスナップショット数の条件下で到来方向推定を行った場合に達成可能な推定誤差の下限である CRB (Cramér-Rao Bound) について説明した。

第3章では、整数角度における DNN の適用可能性について検討した。基本的な順伝播型全結合ネットワークの定式化を行い、誤差逆伝播法に基づく勾配降下法によるネットワークの訓練について説明した。アレーアンテナから得られる受信データ相関行列を入力し、離散角度スペクトルが出力されるような DNN を設計した。等しい電力を有する無相関な狭帯域信号2波が互いに重複しない2つの整数角度から到来する条件において、DNN の基本的な性能評価を行った。SNR を種々のパターンで変化させながら DNN を訓練し、訓練データの SNR によって推定精度が変化することを述べた。一般に推定が困難とされる近接波の推定精度を評価するため、2波の到来角度差が 1° である条件で DNN を訓練した。その結果、 1° 近接という厳しい到来条件であっても、 1° 近接条件で訓練した DNN を用いることで Root-MUSIC を超える極めて高い精度で推定が行えることを確認した。このような、ある特定の環境に特化したモデルを、到来角度差の制約なしに訓練した汎用的な DNN と補完的に用いることで、ランダム2波推定の精度をさらに改善できることを示した。

第4章では、実数角度におけるDNNの適用可能性について検討した。DNNの中間層とユニット数を変化させて訓練を行い、推定精度を評価した。DNNの出力として設定した角度グリッドの境界上に信号が到来した場合に、境界を挟んで隣り合う2つのユニットの出力が大きくなり、隣接ユニットへ誤る場合があることを確認した。この問題を解決するため、従来の角度グリッドをもつDNN Aと、そのグリッドと境界が重ならないよう 0.5° ずらしてグリッドをスタagger配置したDNN Bを組み合わせる手法を提案した。この手法により、グリッド間隔を狭めたDNNを訓練するよりも簡易に、Root-MUSICを超える推定精度が得られることを示した。実数角度の到来条件においても、 1° 近接条件で訓練したDNNがその条件で極めて高い推定精度を示すことを確認した。スタagger配置、または 1° 近接条件で訓練したDNNから得られた2通りの推定結果を理想的に選択することでランダム2波推定の精度が向上することを示した。

第5章では、具体的な組み合わせ手法の検討と推定精度の更なる向上のため、到来角度差が 1° であったかを検出するDNNと、SNRを推定するDNNを構築した。 1° 近接波を検出するDNNを用いて、 1° 近接条件で訓練したDNNと、到来角度差の制約なしに訓練したDNNを切り替えて推定する手法を提案した。これにより、到来角度差に関する事前知識がなくとも、 1° 近接波が推定可能となり、RMSEが大きく改善することを示した。SNRが異なるデータセットでDNNを訓練した結果、推定時と同じSNRで訓練したDNNが、そのSNRにおいて最も高い推定成功率を示すことを確認した。SNRを推定するDNNを訓練し、その推定結果に基づいて異なるSNRで訓練したDNNから最適なものを選択する手法を提案した。これにより、高SNR時の推定成功率を維持しつつ、低SNR時の推定成功率が大幅に改善することを示した。

謝辞

本研究は，著者が北海道大学 大学院情報科学院 情報科学専攻 博士後期課程在籍中に，同校 大鐘武雄 教授の指導のもと行ったものである．本研究を進めるにあたり，手厚い御指導，幾多の貴重な御助言を頂いた大鐘武雄 教授に深甚の謝意を表す．副査として，細部にわたり御助言を頂いた同校 西村寿彦 教授，同校 齊藤晋聖 教授に深謝の意を表す．

本研究を進めるにあたり，種々御助言，御援助を頂いた株式会社 NTT ドコモ 6G-IOWN 推進部 岸山祥久 氏，来山大祐 氏に感謝の意を表す．また，旭川工業高等専門学校 電気情報工学科在籍時に電波の到来方向推定の研究を始めるきっかけを与えて頂いた同校 大島功三 教授，北海道大学入学前のインターンシップ中から入学後も変わらず御指導，御助言を頂いた北海道大学 小川恭孝 名誉教授，光通信の分野から御助言を頂いた同校 佐藤孝憲 准教授に感謝の意を表す．

本研究の一部は，北海道大学国際連携研究教育局ビッグデータ・サイバーセキュリティグローバルステーションの支援を受けて行われた．

加瀬 裕也

2022 年 3 月

研究業績

論文

- (1) Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, D. Kitayama, Y. Kishiyama, “Fundamental Trial on DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E103-B, no. 10, pp. 1127–1135, Oct. 2020, DOI:10.1587/transcom.2019EBP3260.
- (2) Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, T. Sato, Y. Kishiyama, “Accuracy Improvement in DOA Estimation with Deep Learning”, *IEICE Trans. Commun.*, vol. E105-B, no. 5, May 2022 (Advance publication), DOI:10.1587/transcom.2021EBT0001.

講演

- (1) 加瀬裕也, 西村寿彦, 大鐘武雄, 小川恭孝, “深層学習を用いた到来方向推定の基礎的検討,” 信学技報, vol. 118, no. 125, RCS2018-88, pp. 51–55, July 2018.
- (2) Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, D. Kitayama, and Y. Kishiyama, “DOA estimation of two targets with deep learning,” *Proc. IEEE WPNC 2018*, Oct. 2018, DOI:10.1109/WPNC.2018.8555814.
- (3) 加瀬裕也, 西村寿彦, 大鐘武雄, 小川恭孝, 来山大祐, 岸山祥久 “深層学習を用いた到来方向推定の検討,” 信学総大, B-5-63, p. 329, Mar. 2019.
- (4) 加瀬裕也, 西村寿彦, 大鐘武雄, 小川恭孝, 来山大祐, 岸山祥久, “深層学習を用いた到来方向推定法の検討,” 信学技報, vol. 119, no. 8, RCS2019-17, pp. 79–84, Apr. 2019.
- (5) 加瀬裕也, 西村寿彦, 大鐘武雄, 小川恭孝, 来山大祐, 岸山祥久, “深層学習を用いた近接波の到来方向推定の検討,” 信学技報, vol. 119, no. 108, RCS2019-132,

- pp. 155–160, July 2019.
- (6) Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, D. Kitayama, and Y. Kishiyama, “Performance analysis of DOA estimation of two targets using deep learning,” *Proc. WPMC 2019*, Nov. 2019, DOI:10.1109/WPMC48795.2019.9096165.
 - (7) 加瀬裕也, 西村寿彦, 大鐘武雄, 小川恭孝, 来山大祐, 岸山祥久, “深層学習を用いた到来方向推定における DNN 構成に関する検討,” 信学総大, B-5-39, Mar. 2020.
 - (8) 加瀬裕也, 佐藤孝憲, 西村寿彦, 大鐘武雄, 小川恭孝, 来山大祐, 岸山祥久, “深層学習を用いた到来方向推定における精度向上に関する検討,” 信学技報, vol. 120, no. 89, RCS2020-68, pp. 61–66, July 2020.
 - (9) Y. Kase, T. Nishimura, T. Ohgane, Y. Ogawa, T. Sato, D. Kitayama, and Y. Kishiyama, “A consideration on accuracy improvement in DOA estimation of two targets with deep learning,” *Proc. ICETC 2020*, P1-3, Dec. 2020, DOI:10.34385/proc.63.P1-3.
 - (10) 加瀬裕也, 西村寿彦, 大鐘武雄, 小川恭孝, 佐藤孝憲, 岸山祥久, “深層学習を用いた近接波の到来方向推定における精度向上に関する検討,” 信学技報, vol. 121, no. 103, RCS2021-97, pp. 98–103, July 2021.