

様々な無線信号波形を用いた機械学習による通信環境推定

電子情報通信学会 総合大会
[AT-1] AIと無線通信の接点



東京大学 生産技術研究所

小島 駿

2025/3/27

自己紹介



小島 駿

経歴

- ✓ 2022年9月～現在：東京大学 生産技術研究所 特任助教（杉浦研究室）
- ✓ 2021年4月～2022年8月：宇都宮大学 工学部 情報電子オプティクスコース 助教
- ✓ 2019年9月～2021年3月：千葉大学 大学院 融合理工学府 基幹工学専攻 博士後期課程

研究の興味

- ✓ 無線通信における機械学習応用
通信環境推定, セマンティック通信
- ✓ 物理層セキュリティ
秘密鍵生成, 量子鍵配送



Homepage

<https://sites.google.com/view/shun-kojima>

本発表の構成

1. 研究背景

2. これまでの研究内容

- A) CNNを用いた様々な受信信号波形による通信環境推定
- B) 複数の受信信号波形のマルチモダリティによる通信環境推定の高精度化
- C) 敵対的生成ネットワークによる通信環境推定用データセットの拡張

3. 将来の研究動向


1. 研究背景



次世代の無線通信の実現に向けて


- IoTの発展に伴い、世界的に通信端末数は増加傾向にある
- 要求されるデータトラフィックは爆発的に増加している

Number of Devices



Cisco Annual Internet Report, 2018-2023

Estimations of global mobile traffic



Created based upon data from ITU-R "Report ITU-R M.2370"

次世代通信の実現における技術課題

✓ 大規模通信システム

- 伝搬路情報推定
- システム実行に関わる計算量の増加
- 適応制御

✓ 高周波数帯を用いた通信

- 新たなチャネルモデリング
- テラヘルツ信号の取得・追跡技術
- 超高速変調技術

✓ 周波数共有

- 周波数利用効率の改善
- 無線トラフィックの管理

✓ セキュリティの強化

- 多様化・高度化する攻撃への対策
- 大規模ネットワークのセキュリティ
- セキュアなデータ伝送・保存管理


✓ 通信・センシング統合処理

- リアルタイム性
- 精度・速度の両立
- ハードウェアとデバイスの設計

✓ エネルギー効率


- ネットワーク全体の低消費電力化
- エネルギーハーベスティングの実現

無線通信の進化




機械学習応用に関する技術動向

5G/BeyondにおけるAI/ML関連技術の特許・論文件数は増加傾向



Intricate Research, “The role of AI/ML in 5G Advanced” 2023



S. Szott *et al.*, *IEEE Commun. Surv. Tutor.*, vol. 24, no. 3, 2022.

無線通信における機械学習応用の隆盛の要因

1. 高度な信号処理技術の要求

- 信号処理の高精度化
- 低遅延化・低消費電力化への可能性

2. 他分野における機械学習応用成功の波及効果

- 画像認識・音声認識・自然言語処理等の分野での大きな成功
- 医療等の他分野にも急速に普及
- 深層学習技術の持つ普遍性への可能性が明らかとなってきている

3. 計算機能力の向上

- GPUの性能向上により大規模並列計算が可能となり、機械学習と高い親和性を持つ
- 大量のデータの高速処理が実現
- IoT等の小型デバイスによるデータ収集の容易化

2. これまでの研究内容



本発表で紹介する研究内容

A) 受信信号波形を用いた機械学習による複数の通信環境の同時推定

⇒ 適応制御に不可欠な通信環境情報の推定に係る計算量を削減しつつ、高度な推定精度を実現

B) 異なる受信信号波形のマルチモダリティによる通信環境推定の高精度化

⇒ 複数波形のマルチモダリティを活用することで、通信環境に関する特徴抽出の効率化・高精度化への展開

C) 敵対的生成ネットワークによる通信環境推定用データセットの拡張

⇒ 少ない無線通信学習データ・計算リソースからでも十分な特徴抽出を達成

2-A) 受信信号波形を用いた機械学習による 複数の通信環境同時推定

1. **S. Kojima***, Y. Goto, K. Maruta, S. Sugiura, and C. Ahn, “Timing Synchronization Based on Supervised Learning of Spectrogram for OFDM Systems,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 9, no. 5, pp. 1141-1154, Oct. 2023.
2. **S. Kojima***, *et al.*, “CNN based Joint SNR and Doppler Shift Classification using Spectrogram Images for Adaptive Modulation and Coding,” *IEEE Trans. Commun.*, vol. 69, no. 8, pp. 5152-5167, May 2021.
3. **S. Kojima***, K. Maruta, and C. Ahn, “Adaptive Modulation and Coding using Neural Network based SNR Estimation,” *IEEE Access*, vol. 7, pp. 183545-183553, 2019.

2-A) 研究背景

適切な通信パラメータの制御には ...

- SNR (信号対雑音電力比), ドップラーシフト, Kファクタ, タイミングオフセットなどの要因によって通信環境は決定される
- 受信側で通信環境情報を取得し, 送信側へのフィードバックが不可欠
- 一般的には送受信機において既知となる参照信号を用いて伝搬路に関する情報の推定を行う



参照信号なしでこれらの値を推定し適応変調符号化などの適応制御方式に応用することができれば通信性能の最大化が期待される


2-A) 提案方式

現実環境を想定した場合は ...

- ✓ 複数のパラメータの同時推定が必要不可欠
- ✓ 参照信号を用いずに取得可能な情報から可能な限り多くの情報を取得できれば計算処理の削減につながる

Proposal

受信信号のスペクトログラム波形を入力として用いた畳み込みニューラルネットワーク (CNN: convolutional neural network) による複数通信環境の同時推定法



2-A) 受信信号のスペクトログラム

CNNの入力画像 (スペクトログラム)




Fig.1: Spectrum




Fig.2: Spectrogram


- ✓ スペクトルは受信信号をフーリエ変換した2次元グラフである (縦軸: 振幅, 横軸: 周波数)
- ✓ OFDM信号ではガードバンドによりノイズの特徴がスペクトルに現れる
- ✓ スペクトログラムはスペクトルを複数シンボルにわたって表示したものである (縦軸: 時間, 横軸: 周波数, 色: 振幅)
- ✓ スペクトログラムではSNRの特徴だけでなくドップラーシフト, Kファクタによる電力分布の変化も確認できる

2-A) スペクトログラムの生成法


CNNの入力画像（スペクトログラム）

$$P(f, t) = \left| \sum_{t=t_f}^{T+t_f-1} r(t) w_s(t - t_f) e^{-j2\pi f(t-t_f)} \right|^2$$


w_s : window function
 $r(t)$: received signal




(i) $K = 0$, Doppler = 10Hz



(ii) $K = 10$, Doppler = 10Hz




(iii) $K = 0$, Doppler = 1000Hz



(iii) $K = 10$, Doppler = 1000Hz


これらの比較によりドップラーシフト・Kファクタの変化による影響がスペクトログラム中の電力変動といった形で明確に現れていることが確認できる




**SNRに加えドップラーシフト・Kファクタの特徴を
スペクトログラムから同時に抽出することが可能で
ある**

2-A) 様々な通信環境が与える影響


SNR、ドップラー周波数、Kファクタを様々に変化したスペクトログラム画像




(a) $K = 0$, SNR = 0 dB, Doppler = 0.001 Hz




(b) $K = 0$, SNR = 30 dB, Doppler = 0.001 Hz




(c) $K = 10$, SNR = 0 dB, Doppler = 0.001 Hz




(d) $K = 10$, SNR = 30 dB, Doppler = 0.001 Hz




(e) $K = 0$, SNR = 0 dB, Doppler = 1000 Hz



(f) $K = 0$, SNR = 30 dB, Doppler = 1000 Hz




(g) $K = 10$, SNR = 0 dB, Doppler = 1000 Hz



(h) $K = 10$, SNR = 30 dB, Doppler = 1000 Hz

2-A) 波形形式変換による高精度な通信環境推定


畳み込みニューラルネットワークを用いた3パラメータ同時推定法の概要



- ✓ スペクトログラムを入力画像として用いるため**参照信号を必要としない**
- ✓ 実際の推定にはオフラインで学習させたネットワークを用いることで受信側での**計算負荷を削減可能**
- ✓ 1パケットのスペクトログラムから複数パラメータを推定可能であり受信信号の大規模なサンプリングを必要としない

2-A) シミュレーションパラメータ


Parameters	Values
Fading	Rician fading
Number of subcarriers	50
FFT size	64
FEC	Convolutional code



Layer	Output dimensions
Input	$256 \times 256 \times 3$
Conv2D (filters: 8) + ReLU	$256 \times 256 \times 8$
Max-Pooling (2×2)	$128 \times 128 \times 8$
Conv2D (filters: 16) + ReLU	$128 \times 128 \times 16$
Max-Pooling (2×2)	$64 \times 64 \times 16$
Conv2D (filters: 32) + ReLU	$64 \times 64 \times 32$
Max-Pooling (2×2)	$32 \times 32 \times 32$
Conv2D (filters: 64) + ReLU	$32 \times 32 \times 64$
Max-Pooling (2×2)	$16 \times 16 \times 64$
Conv2D (filters: 128) + ReLU	$16 \times 16 \times 128$
Max-Pooling (2×2)	$8 \times 8 \times 128$
Conv2D (filters: 256) + ReLU	$8 \times 8 \times 256$
Max-Pooling (2×2)	$4 \times 4 \times 256$
Conv2D (filters: 512) + ReLU	$4 \times 4 \times 512$
Max-Pooling (2×2)	$2 \times 2 \times 512$
Fully Connected + ReLU	256
Dropout (0.5)	128
Fully Connected + Softmax	Classification outputs

2-A) シミュレーション結果

SNRのみの推定（分類）精度の比較結果




Classification accuracy of SNR

様々なSNR間隔の3パターンの分類問題

- ✓ ドップラーシフトが小さく, K が大きい理想的な通信環境における精度が**最も高い**
- ✓ ドップラーシフトが大きくなると K の値に関わらず精度が**劣化する**
- ✓ SNRを推定する場合において K の影響は小さいがドップラーシフトによる影響は大きい

2-A) シミュレーション結果

ドップラーシフトのみの推定（分類）精度の比較結果




Classification accuracy of Doppler shift

様々なドップラー間隔の3パターンの分類問題

- ✓ Kの値によらずSNRが大きい場合の方が**優れた分類精度を示す**
- ✓ 分類するドップラーシフト間隔によって**Kの影響は変化する**
- ✓ ドップラーシフト間隔が小さい場合ではKが大きい方が、間隔が大きい場合ではKが小さい方が優れた分類精度を示す

2-A) シミュレーション結果

Kファクタのみの推定（分類）精度の比較結果



Classification accuracy of K-factor

様々なKファクタ間隔の3パターンの分類問題

- ✓ K进行分类する場合, SNRの値にほとんど影響されない
- ✓ ドップラーシフトの影響は顕著でありドップラーシフトが大きい場合分類精度は**大きく劣化する**
- ✓ Kの間隔に関わらず, ドップラーシフトが小さい場合では90%近い精度を維持可能

2-A) シミュレーション結果

3パラメータの同時推定精度の比較結果（混同行列）

Predict Class	K = 0 0.001 Hz 0 dB	1000 12.5%	0 0.0%	1 0.0%	0 0.0%	8 0.1%	0 0.0%	0 0.0%	0 0.0%	99.1%
	K = 0 0.001 Hz 30 dB	0 0.0%	969 12.1%	0 0.0%	0 0.0%	0 0.0%	21 0.3%	0 0.0%	0 0.0%	97.9%
	K = 10 0.001 Hz 0 dB	0 0.0%	0 0.0%	927 11.6%	0 0.0%	166 2.1%	0 0.0%	12 0.1%	0 0.0%	83.9%
	K = 10 0.001 Hz 30 dB	0 0.0%	4 0.1%	0 0.0%	913 11.4%	0 0.0%	88 1.1%	0 0.0%	8 0.1%	90.1%
	K = 0 100 Hz 0 dB	0 0.0%	0 0.0%	16 0.2%	0 0.0%	810 10.1%	0 0.0%	5 0.1%	0 0.0%	97.5%
	K = 0 100 Hz 30 dB	0 0.0%	26 0.3%	0 0.0%	31 0.4%	0 0.0%	874 10.9%	0 0.0%	2 0.0%	93.7%
	K = 10 100 Hz 0 dB	0 0.0%	0 0.0%	56 0.7%	0 0.0%	16 0.2%	0 0.0%	983 12.3%	0 0.0%	93.2%
	K = 10 100 Hz 30 dB	0 0.0%	1 0.0%	0 0.0%	56 0.7%	0 0.0%	17 0.2%	0 0.0%	990 12.4%	93.0%
Precision		100%	96.9%	92.7%	91.3%	81.0%	87.4%	98.3%	99.0%	93.3%
		K = 0 0.001 Hz 0 dB	K = 0 0.001 Hz 30 dB	K = 10 0.001 Hz 0 dB	K = 10 0.001 Hz 30 dB	K = 0 100 Hz 0 dB	K = 0 100 Hz 30 dB	K = 10 100 Hz 0 dB	K = 10 100 Hz 30 dB	Recall
Target Class										

8パターンの分類問題における混同行列

- ✓ ドップラーシフトの誤判定が最も多い傾向にある
- ✓ SNRによる誤判定はほとんどない
- ✓ スペクトログラム中にSNRの特徴は色として明確に現れるが, ドップラーシフト・Kファクタは信号電力部分のゆがみとして現れ特徴が不規則なため誤判定が多くなる

2-A) シミュレーション結果

3パラメータの同時推定（分類）精度の比較結果

計99パターンの分類問題

Number of Epoch	10	20	40
Accuracy [%]	46.74	67.30	69.88

- ✓ SNR = [0, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50dB], ドップラーシフトが0.001, 100, 500Hz, Kファクタが0, 5, 10の場合の計99パターン
- ✓ データセットとして各クラス3000枚ずつ, うち80%を学習データ, 10%を検証データ, 10%をテストデータとして用いている
- ✓ 学習エポックを増やすにつれ**精度が向上**
- ✓ パターンが少ない場合と比較した分類精度の劣化の要因は**データ数の不足**

2-B) 異なる受信信号波形のマルチモダリティによる 通信環境推定の高精度化


4. K. Tamura, **S. Kojima***, P. Trinh, S. Sugiura, and C. Ahn, “Joint SNR and Rician K-Factor Estimation Using Multimodal Network over Mobile Fading Channels,” *IEEE Trans. Mach. Learn. Commun. Netw.*, vol. 2, pp. 766-779, Jun. 2024.
5. K. Tamura, **S. Kojima**, S. Sugiura, J. Cha, and C. Ahn, “Accurate and Doppler Robust SNR Estimation using Multimodal CNN,” *Proc. IEEE 99th Vehicular Technology Conference (VTC 2024 - Spring)*, pp. 1 - 5, Singapore, Jun. 2024.

2-B) 研究背景

より高品質な通信環境推定を実現するには ...

✓ 多様かつ莫大な信号データセットが必要

→ 現実の無線通信環境では、時間やコスト、リソースの問題で難しい




Proposal

異なる受信信号波形のマルチモダリティによる通信環境推定の高精度化

- ✓ 少ないデータセット環境下においてもネットワーク構造の最適化と効率的な特徴量抽出を実現
- ✓ 計算量・処理速度を維持しつつ高精度化を達成可能

2-B) 提案法

- ✓ 提案法は、2つの独立の入力に対し、それぞれ個別のCNNにより特徴抽出を行い、最後に結合する構造
- ✓ 未加工の受信信号データとスペクトログラム波形を入力として用いる
- ✓ 今回は簡単化のため、SNRとKファクタの2つのパラメータを推定対象とする



2-B) シミュレーション結果

計算量・学習データセットサイズの比較結果

- ✓ 左側：SNRを推定した場合の処理速度・FLOP数の従来法との比較
- ✓ 右側：SNR推定時に学習に用いたデータセットの大きさによる影響の比較

Scheme	Processing time [ms]	FLOPs	Accuracy [%]
M ₂ M ₄ [6]	3.70×10^{-3}	39.0 K	23.04
Spectrogram [11]	1.78	33.1 M	34.60
TL [15]	5.51	30.9 G	29.80
Sequence [16]	0.82	10.7 M	32.83
GAN [20]	1.80	33.1 M	34.35
Proposal	2.24	40.2 M	63.08

Scheme\Dataset	100	300	500	1000	2000	5000
Spectrogram [11]	51.80	54.94	57.85	58.20	60.31	62.72
TL [15]	54.26	56.70	57.20	57.65	59.07	61.32
Sequence [16]	33.55	44.10	56.34	60.61	75.69	91.32
GAN [20]	49.42	55.03	58.02	58.86	60.82	62.77
Proposal	55.66	83.70	97.56	99.72	99.74	99.82

[6] D. R. Pauluzzi and N. C. Beaulieu, “A comparison of SNR estimation techniques for the AWGN channel,” *IEEE Trans. Commun.*, vol. 48, no. 10, pp. 1681–1691, Oct. 2000.

[11] S. Kojima, *et al.*, “CNN-based joint SNR and Doppler shift classification using spectrogram images for AMC,” *IEEE Trans. Commun.*, vol. 69, no. 8, pp. 5152–5167, Aug. 2021.


[15] X. Xie, S. Peng, and X. Yang, “Deep learning-based signal-to-noise ratio estimation using constellation diagrams,” *Mobile Inf. Syst.*, vol. 2020, pp. 1–9, Nov. 2020.

[20] Z. Tang, *et al.*, “Data augmentation for signal modulation classification using GAN,” *Proc. IEEE 4th Int. Conf. Electron. Inf. Commun. Technol.*, Aug. 2021, pp. 450–453.


2-B) シミュレーション結果

SNR推定精度の比較結果

従来法との比較




様々なKファクタにおける比較




2-B) シミュレーション結果

Kファクタ推定精度の比較結果

従来法との比較



様々なSNRにおける比較



2-B) シミュレーション結果

同時推定した場合の混同行列

SNR:4, K-factor:2

Predict Class	SNR: 0dB K: 0	69 8.6%	31 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	69.0% 31.0%
	SNR: 0dB K: 5	35 4.4%	65 3.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	65.0% 35.0%
	SNR: 5dB K: 0	0 0.0%	0 0.0%	83 10.4%	17 2.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	83.0% 17.0%
	SNR: 5dB K: 5	0 0.0%	0 0.0%	23 2.9%	76 9.5%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	76.0% 24.0%
	SNR: 10dB K: 0	0 0.0%	0 0.0%	0 0.0%	0 0.0%	85 10.6%	14 1.8%	1 0.1%	0 0.0%	85.0% 15.0%
	SNR: 10dB K: 5	0 0.0%	0 0.0%	1 0.1%	0 0.0%	10 1.2%	89 11.1%	0 0.0%	0 0.0%	89.0% 11.0%
	SNR: 15dB K: 0	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	89 11.1%	11 1.4%	89.0% 11.0%
	SNR: 15dB K: 5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	15 1.9%	85 10.6%	85.0% 15.0%
	Precision	66.3% 33.7%	67.7% 32.3%	77.6% 22.4%	81.7% 18.3%	89.5% 10.5%	85.6% 14.4%	84.8% 15.2%	88.5% 11.5%	80.1% 19.9%
		SNR: 0dB K: 0	SNR: 0dB K: 5	SNR: 5dB K: 0	SNR: 5dB K: 5	SNR: 10dB K: 0	SNR: 10dB K: 5	SNR: 15dB K: 0	SNR: 15dB K: 5	Recall
Target Class										

SNR:3, K-factor:3


Predict Class	SNR: 0dB K: 0	58 6.4%	26 2.9%	16 1.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	58.0% 42.0%
	SNR: 0dB K: 5	25 2.8%	27 3.0%	48 5.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	27.0% 73.0%
	SNR: 0dB K: 10	3 0.3%	20 2.2%	77 8.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	77.0% 23.0%
	SNR: 5dB K: 0	1 0.0%	0 0.0%	0 0.0%	68 7.6%	25 2.8%	2 0.2%	2 0.2%	2 0.2%	0 0.0%	68.0% 32.0%
	SNR: 5dB K: 5	0 0.0%	0 0.0%	0 0.0%	21 2.3%	52 5.8%	26 2.9%	0 0.0%	1 0.1%	0 0.0%	52.0% 48.0%
	SNR: 5dB K: 10	0 0.0%	0 0.0%	0 0.1%	0 0.0%	14 1.6%	86 9.6%	0 0.0%	0 0.0%	0 0.0%	86.0% 14.0%
	SNR: 10dB K: 0	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	94 10.4%	6 0.7%	0 0.0%	94.0% 6.0%
	SNR: 10dB K: 5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	21 2.3%	51 5.7%	28 3.1%	51.0% 49.0%
	SNR: 10dB K: 10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 1.4%	87 9.7%	87.0% 13.0%
	Precision	66.7% 33.3%	37.0% 63.0%	54.6% 45.4%	76.4% 23.6%	57.1% 42.9%	75.4% 24.6%	80.3% 19.7%	69.9% 30.1%	75.7% 24.3%	66.7% 33.3%
		SNR: 0dB K: 0	SNR: 0dB K: 5	SNR: 0dB K: 10	SNR: 5dB K: 0	SNR: 5dB K: 5	SNR: 5dB K: 10	SNR: 10dB K: 0	SNR: 10dB K: 5	SNR: 10dB K: 10	Recall
Target Class											

2-C) 敵対的生成ネットワークによる通信環境推定用 データセットの拡張

6. 田村幸佑, 小島駿, 赫赫, 丸田一輝, 安昌俊, "GANによるドップラーシフトに堅牢なデータセットの拡張," 電子情報通信学会, 総合大会, no. B-5-5, 2023年3月.
7. 小島駿, 赫赫, 王君ハン, 丸田一輝, 安昌俊, "敵対的生成ネットワークによる受信信号データセットの拡張," 電子情報通信学会, ソサイエティ大会, no. B-5-9, 2022年9月.

2-C) 研究背景

- ✓ 機械学習を無線通信に応用する上で最も重要な作業は**データセットの収集**
- ✓ 機械学習を用いて優れた性能を発揮させるためには**膨大なデータ**が必要
- ✓ しかし**実世界の通信環境は多様**であり大量のデータセットを集めることは**困難**



小さなデータセットから優れた性能
を得られる手法が求められている


2-C) 従来のデータセット拡張

現状で広く用いられているデータセット拡張手法として...

- ✓ トレーニングに使用したデータセットに様々な処理を施し, 見かけ上のデータセットを増やす (例: 画像の向き等の回転、スケール、ノイズの付加など)



Original data



Rotation



Scale




Noise

これらの拡張方式は, 一般的な画像の分類には非常に有効だが, 特に無線通信で用いられる受信信号に対しては効果は限定的

2-C) Generative Adversarial Network (GAN)

- ✓ そこで, 新しいデータを生成できるGAN (Generative Adversarial Network : 敵対的生成ネットワーク) が注目されている [a]




GANは, 生成器が生成したデータと実際の学習データを識別する敵対的な学習により, 高品質なデータを生成することができる

2-C) 提案方式


- ✓ GANの構造をそのまま適用しても、無線信号に対して十分な特徴抽出（SNRやドップラーシフト等）が可能なデータセットを作成することは難しい



無線信号の特質にかなった構造を備えたGANアルゴリズムの構築




2-C) シミュレーション結果



SNR classification accuracy	1dB interval	5dB interval	10dB interval
Generated	86.7 %	98.4 %	100.0 %
Original	66.3 %	74.4 %	81.3 %

2-C) シミュレーション結果

生成データを追加し学習させた場合のSNR分類精度の比較





生成データ数を変化させた場合

- ✓ データセット数は各SNR毎に100枚を適用
- ✓ 従来法では100枚のデータセットからでは十分な特徴抽出が難しく推定精度は最も悪い
- ✓ 提案法により生成したデータセットを追加した場合推定精度は向上する
- ✓ 生成データを追加しすぎた場合は過学習となり劣化する

2-C) シミュレーション結果

従来のデータセット拡張手法との比較



3. 将来の研究動向



研究動向と将来展望

- **ISAC技術として低遅延・低消費電力通信への応用**

- ✓ 限られた計算資源におけるリアルタイム処理・プロトコル設計
- ✓ 異なるデバイスや環境に応じた適切かつ高速な制御

- **セキュリティ・プライバシーと統合した設計**

- ✓ 外部攻撃や信号干渉の検出
- ✓ 攻撃による環境変化に対する動的な対応



- **実機取得データによる検証**

- ✓ シミュレーション値での学習と実機取得データによる学習・テスト結果の性能評価
- ✓ 学習外のデータへのロバスト性の検証・動的制御の可能性の検討

実機実験による検証

提案通信環境推定方式の実環境における有効性の評価として...

- ✓ USRPを送受信機に用いた初期的な伝送実験を実施
- ✓ アンテナ間の距離・電力・遮蔽物体等の通信環境を様々に変化した場合の受信信号データを収集



ありがとうございました。

本研究の成果の一部は、JSPS 科研費(22K14253)、JST ACT-X (JPMJAX22A5) の助成により得られたものです。



Homepage
<https://sites.google.com/view/shun-kojima>