

大規模マルチユーザMIMO検出のための 信念伝搬法と深層学習の融合

高橋 拓海[†] 衣斐 信介[‡] 三瓶 政一[†]

[†]大阪大学 大学院工学研究科

[‡]同志社大学 理工学部

takahashi@comm.eng.osaka-u.ac.jp

自己紹介+謝辞

高橋 拓海

大阪大学 大学院工学研究科 助教 (2019～現在)

研究上の興味：

無線物理層技術のためのベイズ推論に基づく信号処理
(特に信念伝搬法・圧縮センシング)

+ 深層学習

研究協力：

NEC 石井様，村岡様，土井様
白瀬君 (M2学生)

深層学習

□ 画像認識・音声認識・自然言語処理での成功

- 画像・音声認識では、**深層学習**により設計された分類器が人間に匹敵する分類能力を達成 [Wu2015][He2015]

設計指針

- できるだけ余計なことはしない
- 学習がうまく進むことを優先してネットワークを設定
- 多層化してすべてをデータに任せる

- あくまでスペシャルケース...?

□ 関連が薄いと思われていた分野にも急速に波及
→ 制御工学・無線通信工学・信号処理

- ICC・GLOBECOMでも深層学習関連の研究が急増

深層学習

□ 画像認識・音声認識・自然言語処理での成功

- 画像・音声認識では、**深層学習**により設計された分類器が人間に匹敵する分類能力を達成 [Wu2015][He2015]

設計指針

- できるだけ余計なことはしない
- 学習がうまく進むことを優先してネットワークを設定
- 多層化してすべてをデータに任せる

- あくまでスペシャルケース...?

□ 関連が薄いと思われていた分野にも急速に波及

→ 制御工学・無線通信工学・信号処理

- ICC・GLOBECOMでも深層学習関連の研究が急増

深層学習

□ なぜ広い分野に波及したのか？

■ ドメイン知識を活用可能な学習形態の登場・多様化

各分野 (領域) の専門知識・知見



- 問題設定
- モデルの事前知識
- 観測や推定対象の統計的性質

分野固有の**学習モデル・学習形態**

■ 技術の置き換わりではなく境界分野として発展

各分野固有の従来技術 × 深層学習技術

➡ ドメイン知識の活用法が腕の見せ所！！

深層学習

□ なぜ広い分野に波及したのか？

■ ドメイン知識を活用可能な学習形態の登場・多様化

各分野 (領域) の専門知識・知見



- 問題設定
- モデルの事前知識
- 観測や推定対象の統計的性質

分野固有の**学習モデル・学習形態**

■ 技術の置き換わりではなく境界分野として発展

各分野固有の従来技術 × 深層学習技術

➡ ドメイン知識の活用法が腕の見せ所！！

無線通信関連の深層学習技術

□ 無線通信物理層 × 深層学習の境界分野として発展

■ 2019年頃には整理されて見通しが良くなる

和田山 正, “無線通信のための深層展開の基礎,” MIKA, 2019.


和田山 正, “深層学習に基づく無線通信技術 ～ 研究の現状と展望 ～,” 信学技報, 2019.

学習形態	アイデア
ブラックボックス学習	- 深層ニューラルネットワークを利用してモデル表現 - 事前知識必要なし
深層展開	反復構造を有する既存の信号処理アルゴリズムにパラメータを埋め込んだ信号流グラフで深層学習
最適化模擬	凸最適化・非凸最適化アルゴリズムをニューラルネットワークによって模擬
分散学習	分散学習と学習結果の統合
強化学習	報酬に基づく最適戦略の決定

➡ **無線信号処理 × 深層学習** への強力なドメイン知識の活用法

深層展開


- 信号モデルが高精度に与えられた信号処理に対しても
深層学習を活用できる学習形態



反復アルゴリズム


深層展開

- 信号モデルが高精度に与えられた信号処理に対しても
深層学習を活用できる学習形態



反復アルゴリズム

展開




信号流グラフ

深層展開


- 信号モデルが高精度に与えられた信号処理に対しても
深層学習を活用できる学習形態

- 各プロセスが微分可能
- 導関数がほぼ至る所でゼロでない

➡ 誤差逆伝搬が可能




反復アルゴリズム




信号流グラフ

深層展開

- 信号モデルが高精度に与えられた信号処理に対しても深層学習を活用できる学習形態



反復アルゴリズム



信号流グラフ

➡ データ駆動型チューニング

深層展開のメリット

- 各分野固有のアルゴリズムをベースとして利用することで過去の知見をそのまま活用できる
 - モデル駆動型設計とデータ駆動型設計の良いところ取り
- 学習可能パラメータが少なく学習コストが低い
 - オンラインでのファインチューニングも可能
- 学習後のパラメータの振る舞いから知見が得られることも
 - 学習結果の解釈可能性が高い

これまでの深層展開の研究結果

□ 信号処理 × 深層学習

■ スパース信号再構成

- LISTA [Gregor2010], TISTA [Ito2019]
- AMP-inspired deep network [Borgerding2017]

■ MIMO信号検出

- Model-drive deep learning [He2018]
- DL-aided PGD [Tanabe2017]

■ 誤り訂正符号の復号処理

- Linear code [Nachmani2018]
- LDPC code [Wadayama2019]


➡ **収束加速現象** ・ さらなる性能の改善

本研究のモチベーション

□ 工学的視点からの期待：

- 理論モデルと実際の動作環境のモデル誤差の悪影響を深層展開で補償する利用形態

例)




本研究のモチベーション

□ 工学的視点からの期待：

- 理論モデルと実際の動作環境のモデル誤差の悪影響を深層展開で補償する利用形態

例)



本発表の構成

□ 研究背景

- 数理的アルゴリズムの実用化へ向けた取り組みという視点から，深層展開に基づく信号処理設計を考える

□ 信念伝搬法に基づく大規模MIMO検出

- 問題設定
- アルゴリズム解説
- 学習可能パラメータの導入
- 計算機シミュレーション (結果解釈・性能・堅牢性)

□ 後段復号器を考慮した損失関数の設計

- 問題設定
- ネグントロピー
- 計算機シミュレーション

□ まとめ

本発表の構成

□ 研究背景

- 数理的アルゴリズムの実用化へ向けた取り組みという視点から、深層展開に基づく信号処理設計を考える

□ 信念伝搬法に基づく大規模MIMO検出

- 問題設定
- アルゴリズム解説
- 学習可能パラメータの導入
- 計算機シミュレーション (結果解釈・性能・堅牢性)

□ 後段復号器を考慮した損失関数の設計


- 問題設定
- ネグントロピー
- 計算機シミュレーション

□ まとめ

大規模マルチユーザMIMO

基地局受信機
(BS: Base Station)


- データレートの向上
- 通信信頼性の向上
- 多数の端末収容



ユーザ端末
(UE: User Equipment)

大規模マルチユーザMIMO

□ 模式図



$$y' = H' x' + z'$$

実数等価モデル

□ 複素信号モデルを等価な実数信号モデルに変換

複素モデル

$$\mathbf{y}' = \mathbf{H}' \mathbf{x}' + \mathbf{z}'$$



実数等価モデル

$$\mathbf{y} = \mathbf{H} \mathbf{x} + \mathbf{z}$$

$$M \triangleq 2M', N \triangleq 2N'$$

$$\mathbf{y} \triangleq \begin{bmatrix} \Re\{\mathbf{y}'\} \\ \Im\{\mathbf{y}'\} \end{bmatrix} \in \mathbb{R}^{N \times 1}, \mathbf{H} \triangleq \begin{bmatrix} \Re\{\mathbf{H}'\} & -\Im\{\mathbf{H}'\} \\ \Im\{\mathbf{H}'\} & \Re\{\mathbf{H}'\} \end{bmatrix} \in \mathbb{R}^{N \times M},$$

$$\mathbf{x} \triangleq \begin{bmatrix} \Re\{\mathbf{x}'\} \\ \Im\{\mathbf{x}'\} \end{bmatrix} \in \mathbb{R}^{M \times 1}, \mathbf{z} \triangleq \begin{bmatrix} \Re\{\mathbf{z}'\} \\ \Im\{\mathbf{z}'\} \end{bmatrix} \in \mathbb{R}^{N \times 1}$$

解きたい問題


□ 大規模マルチユーザ検出 (大規模な線形の逆問題)

受信 (観測) ベクトル

$$\mathbf{y} \triangleq [y_1, \dots, y_N]^T$$

(観測) 雑音ベクトル

$$\mathbf{z} \triangleq [z_1, \dots, z_N]^T$$



$\mathcal{X} \in \{\chi_1, \dots, \chi_Q\}$ のどれが送信されたか?

最ゆう検出

Q. 解くことは難しい? A. 難しい

◆ 最ゆう推定 (最適検出)

$$\hat{\underline{x}} = \arg \min_{\underline{x} \in \mathcal{X}^M} \|\underline{y} - \underline{H}\underline{x}\|_F^2$$

$$\underline{x} = [\underbrace{\underline{x}_1}_{Q\text{通り}}, \dots, \underbrace{\underline{x}_m}_{Q\text{通り}}, \dots, \underbrace{\underline{x}_M}_{Q\text{通り}}]^T \quad \Rightarrow \quad Q^M\text{通り}$$

➡ 何かしらの**近似**を用いて低計算量で解く必要がある
例) 最適化? ベイズ? ヒューリスティック?

最ゆう検出

Q. 解くことは難しい? A. 難しい

◆ 最ゆう推定 (最適検出)

$$\hat{\underline{x}} = \arg \min_{\underline{x} \in \mathcal{X}^M} \|\underline{y} - \underline{H}\underline{x}\|_F^2$$

$$\underline{x} = [\overset{\text{Q通り}}{\underline{x}_1}, \dots, \overset{\text{Q通り}}{\underline{x}_m}, \dots, \overset{\text{Q通り}}{\underline{x}_M}]^T \quad \Rightarrow \quad \text{Q}^M \text{通り}$$

➡ 何かしらの**近似**を用いて低計算量で解く必要がある
例) 最適化? ベイズ? ヒューリスティック?

信念伝搬法に基づく反復アルゴリズム

□ 信念伝搬法 (BP: Belief Propagation)

大規模な逆問題を解くためのBPに基づく反復アルゴリズムの開発には歴史あり

■ ABP (Approximate BP) [Kabashima2003]

- 統計力学分野の理論に由来 [Thouless1977]
- 別名**GaBP (Gaussian BP)**



大システム極限近似


■ AMP (Approximate Message Passing) [Donoho2009]

通信路行列 $\mathbf{H}$ の各要素が平均ゼロの独立同分布に従うとき
負荷がBP閾値[Takeuchi2015]が小さい場合に
大システム極限でベイズ最適解へ収束 [Bayati2011, Bayati2015]

以降の検討のモチベーション

大規模マルチユーザ検出

- 受信アンテナ素子数の制限 ($N' < 100$)
フルデジタル・消費電力・コスト...
- 受信アンテナ素子間のフェーディング空間相関
受信信号の到来角度広がり の制限...



深層展開をGaBPに導入することで
このモデル誤差の悪影響を抑制できるか?


GaBP・AMPの理想条件

- 大システム極限仮定
- ゼロ平均の独立同分布に従う観測

GaBPに基づく反復アルゴリズム

□ アルゴリズム解説


因子ノード (FN: Factor Node)



変数ノード (VN: Variable Node)

GaBPに基づく反復アルゴリズム

□ アルゴリズム解説



FN 処理

◆ ソフト干渉キャンセル

$$\tilde{y}_{n,m} = y_n - \sum_{i \neq m}^M h_{n,i} \check{x}_{n,i} : \text{干渉成分}$$

◆ $\tilde{y}_{n,m}$ の確率密度関数

$$p_{\tilde{y}_{n,m}|x_m}(\tilde{y}_{n,m}|\chi_q) \sim \mathcal{N}(\mu_{n,m}, \psi_{n,m})$$

スカラーガウス近似 (SGA)

VN 処理

◆ 尤度の結合

$$p_{l_{n,m}|x_m}(l_{n,m}|\chi_q) = \prod_{i \neq n} p_{\tilde{y}_{i,m}|x_m}(\tilde{y}_{i,m}|\chi_q)$$


外部値

◆ ソフトレプリカ生成

$$\check{x}_{n,m} = \sum_{\chi_q} \chi_q \frac{p_{l_{n,m}|x_m}(l_{n,m}|\chi_q)}{\sum_{\chi'_q \in \mathcal{X}} p_{l_{n,m}|x_m}(l_{n,m}|\chi'_q)}$$

GaBPに基づく反復アルゴリズム

□ アルゴリズム解説



FN 処理

◆ ソフト干渉キャンセル

$$\tilde{y}_{n,m} = y_n - \sum_{i \neq m}^M h_{n,i} \tilde{x}_{n,i} : \text{干渉成分}$$

◆ $\tilde{y}_{n,m}$ の確率密度関数

$$p_{\tilde{y}_{n,m} | x_m}(\tilde{y}_{n,m} | \chi_q) \sim \mathcal{N}(\mu_{n,m}, \psi_{n,m})$$

スカラーガウス近似 (SGA)

VN 処理

◆ 尤度の結合

$$p_{l_{n,m} | x_m}(l_{n,m} | \chi_q) = \prod_{i \neq n}^N p_{\tilde{y}_{i,m} | x_m}(\tilde{y}_{i,m} | \chi_q)$$

外部値

◆ ソフトレプリカ生成

$$\tilde{x}_{n,m} = \sum_{\chi_q} \chi_q \frac{p_{l_{n,m} | x_m}(l_{n,m} | \chi_q)}{\sum_{\chi'_q \in \mathcal{X}} p_{l_{n,m} | x_m}(l_{n,m} | \chi'_q)}$$

GaBPに基づく反復アルゴリズム

□ ちょっと補足

x_m に関する情報 $l_{n,m}$ が得られた時の x_m の期待値は?


$$\check{x}_{n,m} = \sum_{\chi_q \in \mathcal{X}} x_m P_{x_m | l_{n,m}}[\chi_q | l_{n,m}] = \sum_{\chi_q \in \mathcal{X}} \chi_q \frac{p_{l_{n,m} | x_m}(l_{n,m} | \chi_q) \cancel{P_{x_m}[\chi_q]}}{\sum_{\chi'_q \in \mathcal{X}} p_{l_{n,m} | x_m}(l_{n,m} | \chi'_q) \cancel{P_{x_m}[\chi_q]}}$$

条件付き期待値

$$= \sum_{\chi_q \in \mathcal{X}} \chi_q \frac{p_{l_{n,m} | x_m}(l_{n,m} | \chi_q)}{\sum_{\chi'_q \in \mathcal{X}} p_{l_{n,m} | x_m}(l_{n,m} | \chi'_q)} \triangleq \eta(l_{n,m})$$

$p_{l_{n,m} | x_m}(l_{n,m} | \chi_q)$ がガウス分布
事前分布: $x_m \in \{-1, +1\}$


↓
tanh関数



GaBPに基づく反復アルゴリズム

□ アルゴリズム解説

因子ノード (FN: Factor Node)



変数ノード (VN: Variable Node)

理想条件が成り立たない通信路環境では
SGAの精度が低下→**深刻な性能低下**

FN 処理

◆ ソフト干渉キャンセル

$$\tilde{y}_{n,m} = y_n - \sum_{i \neq m}^M h_{n,i} \check{x}_{n,i} : \text{干渉成分}$$

◆ $\tilde{y}_{n,m}$ の確率密度関数

$$p_{\tilde{y}_{n,m}|x_m}(\tilde{y}_{n,m}|\chi_q) \sim \mathcal{N}(\mu_{n,m}, \psi_{n,m})$$

スカラーガウス近似 (SGA)

VN 処理

◆ 尤度の結合

$$p_{l_{n,m}|x_m}(l_{n,m}|\chi_q) = \prod_{i \neq n}^N p_{\tilde{y}_{i,m}|x_m}(\tilde{y}_{i,m}|\chi_q)$$

外部値


◆ レプリカ生成

$$\check{x}_{n,m} = \sum_{\chi_q} \chi_q \frac{p_{l_{n,m}|x_m}(l_{n,m}|\chi_q)}{\sum_{\chi'_q \in \mathcal{X}} p_{l_{n,m}|x_m}(l_{n,m}|\chi'_q)}$$

学習可能なGaBP (T-GaBP: Trainable GaBP)

□ 学習可能パラメータの導入


因子ノード (FN: Factor Node)



変数ノード (VN: Variable Node)

学習可能なGaBP (T-GaBP: Trainable GaBP)


□ 学習可能パラメータの導入



ダンピングパラメータ

学習可能なGaBP (T-GaBP: Trainable GaBP)

□ 学習可能パラメータの導入



ダンピングパラメータ

e.g.1) $\forall \zeta_{n,k} \in \{0, 1\}$


$\zeta_{n,k} = 1$: ビリーフをそのまま更新

$\zeta_{n,k} = 0$: ビリーフの更新なし

➡ 従来のスケジューリング法

学習可能なGaBP (T-GaBP: Trainable GaBP)

□ 学習可能パラメータの導入



ダンピングパラメータ

e.g.1) $\forall \zeta_{n,k} \in \{0, 1\}$

$\zeta_{n,k} = 1$: ビリーフをそのまま更新

$\zeta_{n,k} = 0$: ビリーフの更新なし

➡ 従来のスケジューリング法


e.g.2) $\forall \zeta_{n,k} = 0.5$

: ビリーフを過去のビリーフと平均化

➡ 従来のダンピング処理 (Damping)

学習可能なGaBP (T-GaBP: Trainable GaBP)

□ 学習可能パラメータの導入



ダンピングパラメータ

e.g.1) $\forall \zeta_{n,k} \in \{0, 1\}$

$\zeta_{n,k} = 1$: ビリーフをそのまま更新

$\zeta_{n,k} = 0$: ビリーフの更新なし

従来のスケジューリング法

e.g.2) $\forall \zeta_{n,k} = 0.5$

: ビリーフを過去のビリーフと平均化

従来のダンピング処理 (Damping)

e.g.3) $\forall \zeta_{n,k} = 1$


: ビリーフをそのまま更新



通常の GaBP

学習可能なGaBP (T-GaBP: Trainable GaBP)

□ 学習可能パラメータの導入



ダンピングパラメータ

e.g. 4) $\forall \zeta_{n,k} \in [0, 1]$ ←学習により調整

従来のスケジューリング法


従来のダンピング処理

通常の GaBP

これらの手法を学習によって
最適に選択/組み合わせが可能

学習可能なGaBP (T-GaBP: Trainable GaBP)


□ 学習可能パラメータの導入



スケーリングパラメータ導入 [Takahashi2019]


◆ レプリカ生成

$$\check{x}_{n,m}^{(k)} = f(\gamma_{n,m}; \mu_k)$$



学習可能なGaBP (T-GaBP: Trainable GaBP)


□ 学習可能パラメータの導入



スケーリングパラメータ導入 [Takahashi2019]

◆ レプリカ生成

$$\tilde{x}_{n,m}^{(k)} = f(\gamma_{n,m}; \mu_k)$$



◆ 等価利得で規格化 (実は重要)


$$\gamma_{n,m} = \frac{s_{n,m}}{c^2 \cdot \omega_{n,m}}$$

$s_{n,m}$ の等価利得

学習可能なGaBP (T-GaBP: Trainable GaBP)

□ 学習可能パラメータの導入

因子ノード (FN: Factor Node)



変数ノード (VN: Variable Node)

FN 処理

◆ ソフト干渉キャンセル (Soft IC)

$$\tilde{y}_{n,m} = y_n - \sum_{i \neq m}^M h_{n,i} \tilde{x}_{n,i}$$

◆ 尤度情報 (ビリーフ) の算出

$$u_{n,m} = \frac{h_{n,m} \tilde{y}_{n,m}}{\psi_{n,m}}, \quad v_{n,m} = \frac{h_{n,m}^2}{\psi_{n,m}}$$

◆ ダンピングパラメータ導入

$$u_{n,m}'^{(k)} = \zeta_{n,k} \cdot u_{n,m}^{(k)} + (1 - \zeta_{n,k}) \cdot u_{n,m}'^{(k-1)},$$

$$v_{n,m}'^{(k)} = \zeta_{n,k} \cdot v_{n,m}^{(k)} + (1 - \zeta_{n,k}) \cdot v_{n,m}'^{(k-1)}$$

VN 処理

◆ ビリーフの結合


$$s_{n,m}'^{(k)} = \sum_{i=1, i \neq n}^N u_{i,m}'^{(k)}, \quad \omega_{n,m}'^{(k)} = \sum_{i=1, i \neq n}^N v_{i,m}'^{(k)}$$

◆ 適応スケールリング + ソフトレプリカ生成

$$\gamma_{n,m}^{(k)} = s_{n,m}'^{(k)} / (c \omega_{n,m}'^{(k)})$$

$$\tilde{x}_{n,m}^{(k)} \approx c \sum_{\gamma' \in \mathcal{G}_{Q'}} \tanh [\mu_k \cdot (\gamma_{n,m}^{(k)} - \gamma')]$$

T-GaBPのデータ駆動型チューニング



計算機シミュレーション

□ シミュレーション諸元

学習ハイパーパラメータ

パラメータ	値
勾配法	Adamオプティマイザ
学習率	0.005
学習 E_s/N_0	4 dB
学習回数	2000 回
ミニバッチ数	100


BER 特性評価

パラメータ	値
システム構成	$N' = 64, M' = 32, 40, 48$
変調方式	グレイ符号化 16QAM
通信路符号化	なし
通信路モデル	- 無相関レイリーフェージング - 相関係数 ρ の指数減衰Kroneckerモデル

学習されたパラメータの挙動

□ 単純な初期値を用いて学習を行ったT-GaBPの内部パラメータの挙動解釈

K : 繰り返し回数



→ 戦略切り替え

- ・ スケジューリング
- ・ ダンピング
- ・ 全合成 (通常のGaBP)

K : 繰り返し回数



$\mu_k, \forall k$

→ 収束速度の調整



■ 単純な初期値

$$\zeta_{n,k}^{(0)} = 0.5, \forall (n, k)$$

$$\mu_k^{(0)} = 1, \forall k$$

学習されたパラメータの挙動



□ 64×40 の無相関レイリーフェージング通信路 ($\rho = 0.0$)



- $\zeta_{n,k}^{(0)}, \forall (n, k)$ の初期値：そのままOK
- $\mu_k^{(0)}, \forall k$ の初期値：そのままOK

学習されたパラメータの挙動


■ 64×40 のKroneckerモデル ($\rho = 0.7$) に従う有相関通信路



- $\zeta_{n,k}^{(0)}$, $\forall(n, k)$ の初期値: ノード選択法 [Hagiwara2017]
- $\mu_k^{(0)}$, $\forall k$ の初期値: そのままでOK


初期値に違いによる学習過程の変化

□ 異なる初期値を用いたときのLoss (MSE) の変化



E_s/N_0 v.s. BER特性の評価

■ 64×48 の無相関レイリーフェージング通信路 ($\rho = 0.0$)



◆ Linear MMSE

参考特性

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく
強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×48 の無相関レイリーフェージング通信路 ($\rho = 0.0$)



◆ Linear MMSE

参考特性

◆ GaBP

通常のGaBP [Kabashima2003]

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく
強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×48 の無相関レイリーフェージング通信路 ($\rho = 0.0$)



◆ Linear MMSE

参考特性

◆ GaBP

通常のGaBP [Kabashima2003]

◆ T-GaBP w/ init. Param.

学習前の初期パラメータを用いて動作させたT-GaBP

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×48 の無相関レイリーフェージング通信路 ($\rho = 0.0$)



◆ Linear MMSE

参考特性

◆ GaBP

通常のGaBP [Kabashima2003]

◆ T-GaBP w/ init. Param.

学習前の初期パラメータを用いて動作させたT-GaBP

◆ T-GaBP

MSE損失関数に基づいて学習されたパラメータを用いたT-GaBP

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×32 のKroneckerモデル ($\rho = 0.7$) に従う有相関通信路



◆ Linear MMSE

参考特性

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく
強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×32 のKroneckerモデル ($\rho = 0.7$) に従う有相関通信路



◆ Linear MMSE

参考特性

◆ GaBP

通常のGaBP [Kabashima2003]

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく
強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×32 のKroneckerモデル ($\rho = 0.7$) に従う有相関通信路



◆ Linear MMSE

参考特性

◆ GaBP

通常のGaBP [Kabashima2003]

◆ T-GaBP w/ init. Param.

学習前の初期パラメータを用いて動作させたT-GaBP

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく強力なBP検出器

◆ MFB (Matched Filter Bound)

参考特性: 性能下限

E_s/N_0 v.s. BER特性の評価

■ 64×32 のKroneckerモデル ($\rho = 0.7$) に従う有相関通信路



◆ Linear MMSE

参考特性

◆ GaBP

通常のGaBP [Kabashima2003]

◆ T-GaBP w/ init. Param.

学習前の初期パラメータを用いて動作させたT-GaBP

◆ T-GaBP

MSE損失関数に基づいて学習されたパラメータを用いたT-GaBP

◆ EP (Expectation Propagation)


参考特性: MMSE規範に基づく強力なBP検出器

◆ MFB (Matched Filter Bound)


参考特性: 性能下限

M' v.s. BER特性の評価

■ $\text{BER} = 10^{-4}$ を達成するために必要な E_s/N_0



(a) 無相関レイリーフェージング通信路



(b) Kroneckerモデル ($\rho = 0.7$) に従う有相関通信路


学習パラメータの堅牢性評価

- 動作させる環境 (通信路モデル) で学習することにより性能が改善する
- 実用を考えると実際の通信環境は時変
- オンライン学習によって完全に追従することは困難

特定の通信路モデルで学習したパラメータセットは、異なる動作環境に対してどの程度の**堅牢性**を有するのか？

学習パラメータの堅牢性評価

□ 幾何的One-ringモデル



■ 角度広がり

$$\Delta\psi_{m'} = \psi_{m'}^{\max} - \psi_{m'}^{\min}$$

■ i 番目と j 番目の受信アンテナ間の相関係数

$$[\Theta_{m'}]_{i,j} = \frac{1}{\Delta\psi_{m'}} \int_{\psi_{m'}^{\min}}^{\psi_{m'}^{\max}} \exp[j\pi(i-j)\cos(\psi)] d\psi$$


Θ_m : m' 番目の端末の通信路共分散行列

■ m' 番目の端末の通信路ベクトル

$$\mathbf{h}_{m'} = \Theta_{m'}^{1/2} \boldsymbol{\nu}_{m'}, \quad \boldsymbol{\nu}_{m'} \sim \mathcal{CN}(\mathbf{0}, \mathbf{I}_N)$$


学習パラメータの堅牢性評価

■ 64×32 のOne-ringモデルに従う有相関通信路でのBER特性




学習パラメータの堅牢性評価

■ 64×32 のOne-ringモデルに従う有相関通信路でのBER特性




学習パラメータの堅牢性評価

■ 64×32 のOne-ringモデルに従う有相関通信路でのBER特性



学習パラメータの堅牢性評価

64 × 32 のOne-ringモデルに従う有相関通信路でのBER特性



学習パラメータの堅牢性評価

- 受信アンテナ構成 (パターンが) 変化しない限り, 学習されたパラメータは通信環境の変化に対して堅牢
 - ➡ モデル駆動型設計を取り入れた利点
- シミュレーションでいくつかの相関強度に対して学習されたパラメータセットを用意しておけば, 良い初期値となる (ファインチューニング)
- 理想条件下で演繹的に導出されたGaBPに深層展開を適用することで様々な通信環境に対応できる可能性がある

本発表の構成

□ 研究背景

- 数理的アルゴリズムの実用化へ向けた取り組みという視点から，深層展開に基づく信号処理設計を考える

□ 信念伝搬法に基づく大規模MIMO検出

- 問題設定
- アルゴリズム解説
- 学習可能パラメータの導入
- 計算機シミュレーション (結果解釈・性能・堅牢性)

□ 後段復号器を考慮した損失関数の設計

- 問題設定
- ネグントロピー
- 計算機シミュレーション

□ まとめ



複数のモジュールの学習

□ 後段に復号器があるとき学習はどうあるべきか

■ 無符号化システム

■ 符号化システム

検出器単体の学習




複数のモジュールの学習

□ 後段に復号器があるとき学習はどうあるべきか


■ 無符号化システム

検出器単体の学習



■ 符号化システム

検出器+復号器の同時最適化




複数のモジュールの学習

□ 後段に復号器があるとき学習はどうあるべきか


■ 無符号化システム

検出器単体の学習




■ 符号化システム


✗ 検出器+復号器の同時最適化




○ 検出器単体の学習



符号化システムのための損失関数設計




軟入力の前方誤り訂正符号はAWGN通信路に対して最適



ガウス性を評価する尺度として**ネグエントロピー**を導入

符号化システムのための損失関数設計



ネゲントロピー:

$$J_{\text{neg}}(\mathbf{x}) = H_d(\mathbf{x}_{\text{Gauss}}) - H_d(\mathbf{x})$$

非ガウス性を表す尺度

J_{neg} の最小化 → **ガウス性の最大化**

近似式:

$$\tilde{J}_{\text{neg}}(\mathbf{x}) = k_1 \left(\mathbb{E} \left\{ \bar{x} \exp \left[-\frac{\bar{x}^2}{2} \right] \right\} \right)^2 + k_2 \left(\mathbb{E} \left\{ \exp \left[-\frac{\bar{x}^2}{2} \right] \right\} - \frac{1}{\sqrt{2}} \right)^2$$
$$\because k_1 = \frac{36}{8\sqrt{3}-9}, k_2 = \frac{24}{16\sqrt{3}-27}$$

微分エントロピー:


$$H_d(\mathbf{x}) = - \int p_{\mathbf{x}}(\xi) \ln p_{\mathbf{x}}(\xi) d\xi$$

$\mathbf{x}_{\text{Gauss}}$:

$\mathbf{x}$ と同じ平均・分散を持つガウス確率変数


$$\bar{x} = \frac{(x - \mu_x)}{\sigma_x} \quad \begin{array}{l} \mu_x : \text{観測平均} \\ \sigma_x : \text{観測偏差} \end{array}$$

符号化システムのための損失関数設計




MSEとネグエントロピーの重みづけ平均による損失関数

$$J_{\text{loss}} = (1 - w) \cdot J_{\text{mse}} + w \cdot J_{\text{neg}}$$



ネグエントロピーの算出法





◆ グレイ符号化 16QAM の場合

奇数ビット: 4つの混合分布




$$\lambda[c_{m,f}^{(b)}] = \begin{cases} \ln \frac{p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|+3c) + p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|+c)}{p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|-c) + p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|-3c)} & (b=1) \\ \ln \frac{p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|+c) + p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|-c)}{p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|+3c) + p_{l_{m,f}|\mathbf{x}_{m,f}}(l_{m,f}|-3c)} & (b=2) \end{cases}$$

偶数ビット: 2つの混合分布






ネグエントロピーの算出法

i) 奇数ビット



ii) 偶数ビット




計算機シミュレーション

□ シミュレーション諸元

パラメータ	値
システム	符号化 MIMO-OFDM, $(N', M') = (32, 32)$
変調方式	グレイ符号化 16QAM
通信路符号	LDPC (Low-Density-Parity-Check) 符号
符号化率・符号長	$1/3 \cdot 1024 \text{ bit}$
復号器	Sum-Product アルゴリズム
サブキャリア間隔	60 kHz
通信路遅延モデル	TDL (Tapped Delay Line) – B モデル
通信路遅延拡がり	300 ns
空間相関	Kronecker モデル, 相関係数 $\rho = 0.6$
勾配法	Adam
学習率	0.005
学習 E_s/N_0	2 dB
学習回数	2000 回
ミニバッチ数	100

計算機シミュレーション

■ 重みパラメータ w の最適化




■ 下に凸の形状となり，最適値を持つ

➡ **ネグエントロピーとMSEの両方を考慮する必要あり**

■ w はMCSなどの通信パラメータに応じて決定？


E_s/N_0 v.s. BER特性の評価

■ 32×32 のKroneckerモデルに従う有相関通信路




E_s/N_0 v.s. BER特性の評価

■ 32×32 のKroneckerモデルに従う有相関通信路




E_s/N_0 v.s. BER特性の評価

■ 32×32 のKroneckerモデルに従う有相関通信路




E_s/N_0 v.s. BER特性の評価

■ 32×32 のKroneckerモデルに従う有相関通信路 (16QAM)



E_s/N_0 v.s. BER特性の評価

■ 32×32 の無相関レイリーフェージング通信路 (256QAM)



まとめ

□ GaBPに基づく大規模マルチユーザMIMO検出を通して

- ◆ 学習可能なアルゴリズム設計
- ◆ 学習後のパラメータ解釈
- ◆ 性能評価

を行い、深層展開に基づくアルゴリズム設計の有効性について議論した

□ 深層展開の謳い文句は (割と) 本当

- データ駆動によるモデル誤差の悪影響抑制
- モデル駆動によるパラメータの堅牢性
- **パラメータ設計と損失関数設計が重要**

ご清聴ありがとうございました!

参考文献

- [Wu2015] Wu et al., “Deep Image: Scaling up Image Recognition,” 2015.
- [He2015] He et al., “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” 2015.
- [Gregor2010] K. Gregor et al., “Learning fast approximations of sparse coding,” Proceedings of the 27th ICML, p.399–406, ICML’10, Omnipress, Madison, WI, USA, 2010.
- [Ito2019] D. Ito et al., “Trainable ISTA for sparse signal recovery,” IEEE Trans. Sig. Proc., vol.67, no.12, pp.3113–3125, 2019.
- [Borgerding2017] M. Borgerding et al., “AMP-inspired deep networks for sparse linear inverse problems,” IEEE Trans. on Signal Processing, vol.65, no.16, pp.4293–4308, 2017.
- [He2018] H. He et al., “A model-driven deep learning network for MIMO detection,” IEEE GlobalSIP, pp.584–588, 2018.
- [Tanabe2019] S. Takabe et al., “Deep learning-aided projected gradient detector for massive overloaded MIMO channels,” IEEE ICC, pp.1–6, 2019.
- [Nachmani2018] E. Nachmani et al., “Deep learning methods for improved decoding of linear codes,” IEEE J. Sel. Top. Signal Process., vol.12, no.1, pp.119–131, 2018.

参考文献


- [Wadayama2019] T. Wadayama et al., “Deep learning-aided trainable projected gradient decoding for LDPC codes,” IEEE ISIT, pp.2444–2448, 2019.
- [Thouless1977] D. J. Thouless et al., “Solution of ‘solvable model of a spin glass’,” Philos. Mag., vol.35, no.3, pp.593–601, 1977.
- [Kabashima2003] Y. Kabashima, “A CDMA multiuser detection algorithm on the basis of belief propagation,” J.Phys. A: Math. Gen., vol.36, no.43, pp.11111–11121, Oct. 2003.
- [Donoho2009] D. L. Donoho, A. Maleki, and A. Montanari, “Message-passing algorithms for compressed sensing,” Proc. Nat. Acad. Sci., vol.106, no.45, pp.18914–18919, Nov. 2009.
- [Takeuchi2015] K. Takeuchi et al., “Performance improvement of iterative multiuser detection for large sparsely-spread CDMA systems by spatial coupling,” IEEE Trans. Inf. Theory, vol.61, no.4, pp.1768–1794, April 2015.
- [Bayati2011] M. Bayati et al., “The dynamics of message passing on dense graphs, with applications to compressed sensing,” IEEE Trans. Inf. Theory, vol.57, no.2, pp.764–785, Feb. 2011.
- [Bayati2015] M. Bayati et al., “Universality in polytope phase transitions and message passing algorithms,” Ann. Appl. Probab., vol.25, no.2, pp.753–822, April 2015.

参考文献

[Hagiwara2017] M. Hagiwara et al., “Node selection for belief propagation based channel equalization,” IEICE Trans. Commun., vol.E100.B, no.8, pp.1285–1292, 2017.

付録：K v.s. BER特性の評価 (収束加速現象)

■ 無相関レイリーフェージング通信路 ($\rho = 0.0$) @ $E_s/N_0 = 1.0$ dB



付録：学習可能なバイズ最適denoiser


□ 無相関レイリーフェージング通信路 ($\rho = 0.0$) @ $E_s/N_0 = 1.0$ dB

■ QPSK の場合の Soft RG を利用し，多値変調の Soft RG を近似する手法


$$\tilde{x}_{n,m}^{(k)} = \sum_{\chi_q \in \mathcal{X}} \chi_q \frac{\exp \left[\frac{\mu_k}{c^2} \cdot \chi_q \left(\gamma_{n,m}^{(k)} - \frac{1}{2} \chi_q \right) \right]}{\sum_{\chi'_q \in \mathcal{X}} \exp \left[\frac{\mu_k}{c^2} \cdot \chi'_q \left(\gamma_{n,m}^{(k)} - \frac{1}{2} \chi'_q \right) \right]}$$

$$\tilde{x}_{n,m}^{(k)} \approx c \sum_{\gamma' \in \mathcal{G}_{Q'}} \tanh \left[\frac{\mu_k}{c} \cdot (\gamma_{n,m}^{(k)} - \gamma') \right]$$

$$\because \mathcal{G}_{Q'} = \left\{ 2i \cdot c \mid i = 0, \pm 1, \dots, \pm \left(\frac{\sqrt{Q'}}{2} - 1 \right) \right\}$$



➤ QPSKのSoft RG



➤ 16QAMのSoft RG