

# 期待値伝搬法に基づく多次元信号検出のための 自己符号化器に関する一検討

衣斐 信介<sup>1</sup>, 高橋 拓海<sup>2</sup>, 村岡 一志<sup>3</sup>, 土井 隆暢<sup>3</sup>

<sup>1</sup> 同志社大学 理工学部

<sup>2</sup> 大阪大学 大学院工学研究科

<sup>3</sup> 日本電気株式会社 アドバンスネットワーク研究所

電子情報通信学会ソサイエティ大会


【AT-1】AIと無線通信の接点

2025年3月27日(木)15:30～16:15


- 1 無線物理層へのAI(深層学習)の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

- 1 無線物理層へのAI(深層学習)の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ


# 無線物理層への AI(深層学習) の導入レベル




【Lv3】データ駆動アプローチ (WAE)



【Lv1】モデルベース深層学習 (DU)



【Lv2】モデルベース深層学習 (WAE)



【Lv0】モデル駆動アプローチ


## モデルベース深層学習 (ドメイン駆動)

- モデル駆動とデータ駆動のちょうど中間地点
- 確率的数学モデルをドメイン (分野固有の) 知識として活用し、実用上、数理的ツールでは最適化できない部分のみをデータ駆動で最適化
- 理論と実用を橋渡しするものとしての学習技術

# アウトライン


- 1 無線物理層への AI(深層学習) の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

# デジタル通信システム





- **デジタル変調**：ビットを離散複素信号に変換
- **送信フィルタ**：送信スペクトルを帯域制限
- **DAC** (Digital-to-Analog Converter)：デジタル信号をアナログ信号に変換
- **AFE** (Analog Front-End)：ベースバンド信号を実数の正弦波信号に変換
- **ADC** (Analog-to-Digital Converter)：アナログ信号をデジタル信号に変換
- **受信フィルタ**：雑音を抑圧 (SNR 最大化)
- **デジタル復調**：ビット検出

# 変復調 (等価低域系モデル)



中心極限定理を理由に,

- DCMC (Discrete-Continuous Memoryless Channel) に通信路を単純化
- $y[k] = hx[k] + z[k]$
- $z[k]$ : 加法性白色ガウス雑音 (AWGN: Additive White Gaussian Noise)



シンボル誤り率  
の最小化

- 信号点の最小ユークリッド距離の最大化 (数学的に自明)


# アウトライン

- 1 無線物理層への AI(深層学習) の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

# 多次元信号検出

## 空間多重 (Spatial Multiplexing)

- $y = Hx + z$
- $[M, N]$ : [送信, 受信] アンテナ数
- $x = [x_1, \dots, x_M]^T$ : 送信ベクトル
- $y = [y_1, \dots, y_N]^T$ : 受信ベクトル
- $z = [z_1, \dots, z_N]^T$ : 雑音ベクトル
- $H = [h_{n,m}]_{N,M}$ : 通信路行列



### 1 最尤検出

- 検出精度：高い
- 演算量：多い
- $p(y|x)$  の最大化

### 2 繰り返し検出

- 検出精度：中
- 演算量：中
- 干渉キャンセル

### 3 線形推定

- 検出精度：低い
- 演算量：低い
- $\tilde{x} = H^\dagger y$

# 多次元信号検出

## 問題設定:

$$y = Hx + z$$

- 受信ベクトル  $y$  を観測して、未知の送信ベクトル  $x$  を知りたい
- 通信路行列  $H$  は、受信機側で既知
- 送信シンボル  $x_m \in X$  は、 $Q$  値の離散シンボル集合  $X = \{x_1, \dots, x_Q\}$  から一つが選択されたもの。 ※その集合の平均電力密度は  $E_s$
- ランダム雑音  $z_n$  は期待値 0, 分散値  $N_0$  の互いに独立な白色ガウス過程に従う。 ※雑音電力密度は  $N_0$

## 尤度関数

- 送信ベクトル  $x$  が与えられたとき、受信ベクトル  $y$  の条件付き確率密度関数 (PDF: Probability Density Function)

$$p(y|x) = \frac{1}{(\pi N_0)^N} \exp \left[ -\frac{\|y - Hx\|^2}{N_0} \right] \quad (1)$$

# 最大事後確率規範

## 最大事後確率 (Maximum A-posteriori Probability) 規範

- 受信機における信号検出の判定誤り率最小化の最適解

$$\hat{x}_m = \arg \max_{\chi_q \in \mathcal{X}} P[x_m = \chi_q | \mathbf{y}] \quad (2)$$

- 事後確率  $P[x_m | \mathbf{y}]$  はベイズの定理と結合確率の周辺化により,

$$P[x_m = \chi_q | \mathbf{y}] = \frac{p(\mathbf{y} | x_m = \chi_q) P[x_m = \chi_q]}{p(\mathbf{y})} \propto \sum_{\chi_l \in \mathcal{X}^M | x_m = \chi_q} p(\mathbf{y} | \mathbf{x} = \chi_l) P[\mathbf{x} = \chi_l] \quad (3)$$

- $\mathcal{X}^M$  は  $\mathbf{x}$  がとり得る  $M$  次元送信ベクトル候補の直積集合, 総数は  $Q^M$
- $P[\mathbf{x}]$  は送信ベクトルの事前確率 (送信シンボル  $x_m$  に関する事前知識が存在しない場合, 無情報事前分布  $P[\mathbf{x}] = \frac{1}{Q^M}$ )
- $\chi_l \in \mathcal{X}^M | x_m = \chi_q$  は  $m$  番目の送信シンボルが  $\chi_q$  である送信ベクトル候補の一つを意味している

## MAP 規範の全探索による信号検出は,

- その演算量が  $Q$  と  $M$  の値の増加に伴い膨大なものとなる問題に直面

# アウトライン

- 1 無線物理層への AI(深層学習) の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

# 期待値伝搬法 (EP: Expectation Propagation)

## 事前分布:

- MAP 規範  $\Rightarrow$  離散分布 (デルタ関数)  $P[x_m = \chi_q], P[\mathbf{x} = \boldsymbol{\chi}_l]$
- EP  $\Rightarrow$  連続分布  $\Rightarrow$  ガウス分布  $p(\tilde{x}_m = \chi_q), p(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l)$

## 事後分布:

- 尤度関数  $p(\mathbf{y}|\mathbf{x} = \boldsymbol{\chi}_l)$ : ガウス分布, 事前分布  $p(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l)$ : ガウス分布  
 $\Rightarrow$  事後分布  $p(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l|\mathbf{y})$ : ガウス分布

$$f_A(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l) \triangleq p(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l|\mathbf{y}) = \frac{p(\mathbf{y}|\mathbf{x} = \boldsymbol{\chi}_l) \cdot p(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l)}{p(\mathbf{y})} \quad (4)$$

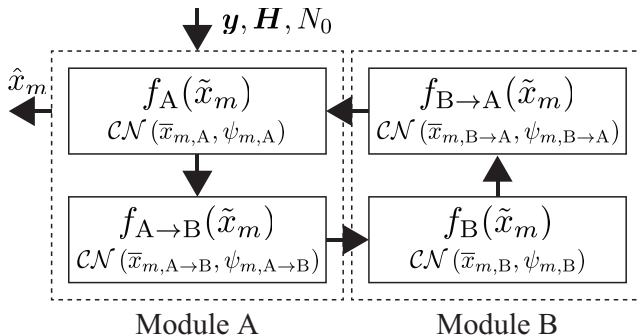
- 式 (4) の周辺分布を, 最終的に求めたい事後分布  $P[x_m = \chi_q|\mathbf{y}]$  に近似,

$$P[x_m = \chi_q|\mathbf{y}] \approx f_A(\tilde{x}_m = \chi_q) = \sum_{\boldsymbol{\chi}_l \in \mathcal{X}^M | x_m = \chi_q} f_A(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l),$$

$$f_A(\tilde{\mathbf{x}} = \boldsymbol{\chi}_l) \propto p(\mathbf{y}|\mathbf{x} = \boldsymbol{\chi}_l) \cdot \prod_{m=1}^M f_{B \rightarrow A}(\tilde{x}_m = [\boldsymbol{\chi}_l]_m), \quad (5)$$

- $f_{B \rightarrow A}(\tilde{x}_m)$  は事前分布  $\leftarrow$  EP の繰り返し信号処理の過程で得られる分布  
「 $m$  が異なれば独立」, 「受信シンボル  $\mathbf{y}$  の雑音成分とは独立」


# 期待値伝搬法 (EP: Expectation Propagation)



## EP アルゴリズム

- 入力：受信ベクトル  $\mathbf{y}$ ，通信路行列  $\mathbf{H}$ ，雑音電力密度  $N_0$
- 出力：最も高い事後分布  $f_A(\tilde{x}_m = \chi_q)$  を持つ  $\chi_q$  の値を判定値  $\hat{x}_m$

# 期待値伝搬法 (EP: Expectation Propagation)



- 事前分布の要件を近似的に満たす方策として、ターボ原理や確率伝搬法で中心的役割を担う外部分布の導入が有効

## EP を理解する上で最も重要な点

4 つの分布  $f_i(\tilde{x}_m)$ , ( $i \in \{A, A \rightarrow B, B, B \rightarrow A\}$ ) を、期待値  $\mathbb{E}_{f_i}\{\tilde{x}_m\} = \bar{x}_{m,i}$  と分散値  $\mathbb{V}_{f_i}\{\tilde{x}_m\} = \psi_{m,i}$  のガウス分布に近似

$$f_i(\tilde{x}_m) \sim \mathcal{CN}(\bar{x}_{m,i}, \psi_{m,i}) \propto \exp \left[ -\frac{|x_m - \bar{x}_{m,i}|^2}{\psi_{m,i}} \right] \quad (6)$$

# 1. モジュール A の事後分布 $f_A(x_m)$

- 式 (5) の事後分布は,

$$\begin{aligned} f_A(\tilde{\mathbf{x}}) &\propto p(\mathbf{y}|\tilde{\mathbf{x}}) \prod_{m=1}^M f_{B \rightarrow A}(\tilde{x}_m) \propto \exp\left[-\frac{\|\mathbf{y} - \mathbf{H}\tilde{\mathbf{x}}\|^2}{N_0}\right] \prod_{m=1}^M \exp\left[-\frac{|\tilde{x}_m - \bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}}\right] \\ &\propto \exp\left[-\left\{\frac{\|\mathbf{y} - \mathbf{H}\tilde{\mathbf{x}}\|^2}{N_0} + (\tilde{\mathbf{x}} - \bar{\mathbf{x}}_{B \rightarrow A})^H \boldsymbol{\Psi}_{B \rightarrow A}^{-1} (\tilde{\mathbf{x}} - \bar{\mathbf{x}}_{B \rightarrow A})\right\}\right] \\ &\propto \exp\left[-\tilde{\mathbf{x}}^H \left(\boldsymbol{\Psi}_{B \rightarrow A}^{-1} + \frac{\mathbf{H}^H \mathbf{H}}{N_0}\right) \tilde{\mathbf{x}} + 2\Re \left\{ \tilde{\mathbf{x}}^H \left(\boldsymbol{\Psi}_{B \rightarrow A}^{-1} \bar{\mathbf{x}}_{B \rightarrow A} + \frac{\mathbf{H}^H \mathbf{y}}{N_0}\right) \right\}\right] \end{aligned} \quad (7)$$

ただし,  $\boldsymbol{\Psi}_{B \rightarrow A} = \text{diag}[\psi_{1,B \rightarrow A}, \dots, \psi_{m,B \rightarrow A}, \dots, \psi_{M,B \rightarrow A}]$

- $f_A(\tilde{\mathbf{x}})$  はガウス分布の結合で構成されているため, 結合後の分布も次式のように, 期待値  $\mathbb{E}_{f_A}\{\tilde{\mathbf{x}}\} = \bar{\mathbf{x}}_A$  と共分散行列  $\mathbb{V}_{f_A}\{\tilde{\mathbf{x}}\} = \boldsymbol{\Psi}_A$  の多次元ガウス分布に従う.

$$\begin{aligned} f_A(\tilde{\mathbf{x}}) &\sim \mathcal{CN}(\bar{\mathbf{x}}_A, \boldsymbol{\Psi}_A) \propto \exp\left[-(\tilde{\mathbf{x}} - \bar{\mathbf{x}}_A)^H \boldsymbol{\Psi}_A^{-1} (\tilde{\mathbf{x}} - \bar{\mathbf{x}}_A)\right] \\ &\propto \exp\left[-\tilde{\mathbf{x}}^H \boldsymbol{\Psi}_A^{-1} \tilde{\mathbf{x}} + 2\Re \left\{ \tilde{\mathbf{x}}^H \boldsymbol{\Psi}_A^{-1} \bar{\mathbf{x}}_A \right\}\right] \end{aligned} \quad (8)$$

# 1. モジュール A の事後分布 $f_A(x_m)$

式 (7) と式 (8) の  $\{\cdot\}$  内の第 1 項と第 2 項を比較すると,

$$\Psi_A^{-1} = \Psi_{B \rightarrow A}^{-1} + \frac{H^H H}{N_0} \quad (9)$$

$$\Psi_A^{-1} \bar{x}_A = \Psi_{B \rightarrow A}^{-1} \bar{x}_{B \rightarrow A} + \frac{H^H y}{N_0} \quad (10)$$

式 (9) より,

$$\Psi_{B \rightarrow A}^{-1} = \Psi_A^{-1} - \frac{H^H H}{N_0} \quad (11)$$

これを式 (10) に代入して整理すると, 期待値  $\bar{x}_A$  は次式となる.

$$\bar{x}_A = \bar{x}_{B \rightarrow A} + \frac{\Psi_A H^H \check{y}}{N_0} \quad (12)$$

$$\check{y} \triangleq y - H \bar{x}_{B \rightarrow A} \quad (13)$$

# 1. モジュール A の事後分布 $f_A(x_m)$

式 (9) の逆行列

$$\Psi_A = \left[ \Psi_{B \rightarrow A}^{-1} + \frac{H^H H}{N_0} \right]^{-1} \quad (14)$$

に対して、逆行列の補助定理

$$[A + BCD]^{-1} = A^{-1} - A^{-1}B[C^{-1} + DA^{-1}B]^{-1}DA^{-1} \quad (15)$$

を適用すると、

$$\Psi_A = \Psi_{B \rightarrow A} - \Psi_{B \rightarrow A} H^H \Omega^{-1} H \Psi_{B \rightarrow A} \quad (16)$$

を得る。ただし、

$$\Omega = H \Psi_{B \rightarrow A} H^H + N_0 I_N \quad (17)$$

# 1. モジュール A の事後分布 $f_A(x_m)$

式 (12) は  $\Omega$  を用いて、次式で表される.

$$\begin{aligned}\bar{x}_A &= \bar{x}_{B \rightarrow A} + \frac{\Psi_A H^H \check{y}}{N_0} \\ &= \bar{x}_{B \rightarrow A} + \frac{1}{N_0} \left( \Psi_{B \rightarrow A} - \Psi_{B \rightarrow A} H^H \Omega^{-1} H \Psi_{B \rightarrow A} \right) H^H \check{y} \\ &= \bar{x}_{B \rightarrow A} + \frac{1}{N_0} \Psi_{B \rightarrow A} \left( H^H - H^H \Omega^{-1} H \Psi_{B \rightarrow A} H^H \right) \check{y} \\ &= \bar{x}_{B \rightarrow A} + \frac{1}{N_0} \Psi_{B \rightarrow A} \left( H^H - H^H \Omega^{-1} [\Omega - N_0 I_N] \right) \check{y} \\ &= \bar{x}_{B \rightarrow A} + \frac{1}{N_0} \Psi_{B \rightarrow A} \left( H^H - H^H + N_0 H^H \Omega^{-1} \right) \check{y} \\ &= \bar{x}_{B \rightarrow A} + \Psi_{B \rightarrow A} H^H \Omega^{-1} \check{y}\end{aligned}\tag{18}$$

# 1. モジュール A の事後分布 $f_A(x_m)$

ここで、大システム極限を考えて、式 (16) の共分散行列  $\Psi_A$

$$\Psi_A = \Psi_{B \rightarrow A} - \Psi_{B \rightarrow A} H^H \Omega^{-1} H \Psi_{B \rightarrow A}$$

を対角近似し、その対角要素を次式で与える。

$$\psi_{m,A} = [\Psi_A]_{m,m} = \psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2 \quad (19)$$

$$\gamma_m \triangleq \mathbf{h}_m^H \Omega^{-1} \mathbf{h}_m \quad (20)$$

したがって、

事後分布  $f_A(\tilde{x}_m)$  の期待値  $\mathbb{E}_{f_A}\{\tilde{x}_m\} = \bar{x}_{m,A}$  と分散値  $\mathbb{V}_{f_A}\{\tilde{x}_m\} = \psi_{m,A}$

$$\bar{x}_{m,A} = \bar{x}_{m,B \rightarrow A} + \psi_{m,B \rightarrow A} \mathbf{h}_m^H \Omega^{-1} \check{\mathbf{y}} \quad (21)$$

$$\psi_{m,A} = \psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2 \quad (22)$$

## 2. モジュール A の外部分布 $f_{A \rightarrow B}(\tilde{x}_m)$

### 外部分布 $f_{A \rightarrow B}(\tilde{x}_m)$ の定義

- 事後分布  $f_A(\tilde{x}_m)$  から事前分布  $f_{B \rightarrow A}(\tilde{x}_m)$  の影響を独立化  $\Rightarrow$  除算

$$f_{A \rightarrow B}(\tilde{x}_m) = \frac{f_A(\tilde{x}_m)}{f_{B \rightarrow A}(\tilde{x}_m)} \propto \exp \left[ - \left\{ \frac{|\tilde{x}_m - \bar{x}_{m,A}|^2}{\psi_{m,A}} - \frac{|\tilde{x}_m - \bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}} \right\} \right] \quad (23)$$

一方、事後分布と事前分布が共にガウス分布に従うのであれば、外部分布  $f_{A \rightarrow B}(\tilde{x}_m)$  も期待値  $\bar{x}_{m,A \rightarrow B}$  と分散値  $\psi_{m,A \rightarrow B}$  を持つガウス分布に従う。

$$f_{A \rightarrow B}(\tilde{x}_m) \sim \mathcal{CN}(\bar{x}_{m,A \rightarrow B}, \psi_{m,A \rightarrow B}) \propto \exp \left[ - \frac{|\tilde{x}_m - \bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \right] \quad (24)$$

式 (23) を展開し、式 (24) と比較すると、

$$\psi_{m,A \rightarrow B} = \frac{\psi_{m,A} \psi_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} \quad (25)$$

$$\bar{x}_{m,A \rightarrow B} = \psi_{m,A \rightarrow B} \left( \frac{\bar{x}_{m,A}}{\psi_{m,A}} - \frac{\bar{x}_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A}} \right) \quad (26)$$

# 補足

$$\begin{aligned}
 & \frac{|\tilde{x}_m - \bar{x}_{m,A}|^2}{\psi_{m,A}} - \frac{|\tilde{x}_m - \bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}} \\
 = & \frac{|\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,A}\} + |\bar{x}_{m,A}|^2}{\psi_{m,A}} - \frac{|\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,B \rightarrow A}\} + |\bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}} \\
 = & \frac{\psi_{m,B \rightarrow A} \left( |\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,A}\} + |\bar{x}_{m,A}|^2 \right)}{\psi_{m,A} \psi_{m,B \rightarrow A}} \\
 & - \frac{\psi_{m,A} \left( |\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,B \rightarrow A}\} + |\bar{x}_{m,B \rightarrow A}|^2 \right)}{\psi_{m,A} \psi_{m,B \rightarrow A}} \\
 = & \frac{(\psi_{m,B \rightarrow A} - \psi_{m,A}) |\tilde{x}_m|^2 - 2\Re\{(\psi_{m,B \rightarrow A} \bar{x}_{m,A} - \psi_{m,A} \bar{x}_{m,B \rightarrow A}) \tilde{x}_m\}}{\psi_{m,A} \psi_{m,B \rightarrow A}} \\
 & + \frac{\psi_{m,B \rightarrow A} |\bar{x}_{m,A}|^2 - \psi_{m,A} |\bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,A} \psi_{m,B \rightarrow A}} \\
 = & \frac{|\tilde{x}_m|^2 - \frac{2\Re\{(\psi_{m,B \rightarrow A} \bar{x}_{m,A} - \psi_{m,A} \bar{x}_{m,B \rightarrow A}) \tilde{x}_m\}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} + \frac{\psi_{m,B \rightarrow A} |\bar{x}_{m,A}|^2 - \psi_{m,A} |\bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A} - \psi_{m,A}}}{\frac{\psi_{m,A} \psi_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}}}
 \end{aligned} \tag{27}$$

$$\begin{aligned}
 f_{A \rightarrow B}(\tilde{x}_m) &\propto \exp \left[ -\frac{|\tilde{x}_m - \bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \right] \\
 &= \exp \left[ -\frac{|\tilde{x}_m|^2 - 2\Re\{\bar{x}_{m,A \rightarrow B} \tilde{x}_m\} + |\bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \right] \quad (28)
 \end{aligned}$$

と比較して

$$\psi_{m,A \rightarrow B} = \frac{\psi_{m,A} \psi_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} \Rightarrow \frac{1}{\psi_{m,A \rightarrow B}} = \frac{1}{\psi_{m,A}} - \frac{1}{\psi_{m,B \rightarrow A}} \quad (29)$$

$$\begin{aligned}
 x_{m,A \rightarrow B} &= \frac{\psi_{m,B \rightarrow A} \bar{x}_{m,A} - \psi_{m,A} \bar{x}_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} \\
 &= \frac{\psi_{m,A} \psi_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} \cdot \frac{\psi_{m,B \rightarrow A} \bar{x}_{m,A} - \psi_{m,A} \bar{x}_{m,B \rightarrow A}}{\psi_{m,A} \psi_{m,B \rightarrow A}} \\
 &= \psi_{m,A \rightarrow B} \left( \frac{\bar{x}_{m,A}}{\psi_{m,A}} - \frac{\bar{x}_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A}} \right) \quad (30)
 \end{aligned}$$

## 2. モジュール A の外部分布 $f_{A \rightarrow B}(\tilde{x}_m)$

式 (25) に式 (22) を代入すると,

$$\begin{aligned}
 \psi_{m,A \rightarrow B} &= \frac{\psi_{m,A} \psi_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} = \frac{(\psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2) \psi_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - (\psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2)} \quad (31) \\
 &= \frac{(\psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2) \psi_{m,B \rightarrow A}}{\gamma_m \psi_{m,B \rightarrow A}^2} = \frac{(1 - \gamma_m \psi_{m,B \rightarrow A})}{\gamma_m} = \frac{1}{\gamma_m} - \psi_{m,B \rightarrow A}
 \end{aligned}$$

式 (26) に式 (22) を代入すると,

$$\begin{aligned}
 \bar{x}_{m,A \rightarrow B} &= \psi_{m,A \rightarrow B} \left( \frac{\bar{x}_{m,A}}{\psi_{m,A}} - \frac{\bar{x}_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A}} \right) = \frac{\psi_{m,B \rightarrow A} \bar{x}_{m,A} - \psi_{m,A} \bar{x}_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - \psi_{m,A}} \\
 &= \frac{\psi_{m,B \rightarrow A} \bar{x}_{m,A} - (\psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2) \bar{x}_{m,B \rightarrow A}}{\psi_{m,B \rightarrow A} - (\psi_{m,B \rightarrow A} - \gamma_m \psi_{m,B \rightarrow A}^2)} \\
 &= \frac{\psi_{m,B \rightarrow A} \bar{x}_{m,A} - \psi_{m,B \rightarrow A} \bar{x}_{m,B \rightarrow A} + \gamma_m \psi_{m,B \rightarrow A}^2 \bar{x}_{m,B \rightarrow A}}{\gamma_m \psi_{m,B \rightarrow A}^2} \\
 &= \frac{\bar{x}_{m,A} - \bar{x}_{m,B \rightarrow A}}{\gamma_m \psi_{m,B \rightarrow A}} + \bar{x}_{m,B \rightarrow A}
 \end{aligned}$$

## 2. モジュール A の外部分布 $f_{A \rightarrow B}(\tilde{x}_m)$

式 (32) に式 (21) を代入すると,

$$\begin{aligned}\bar{x}_{m,A \rightarrow B} &= \frac{\bar{x}_{m,A} - \bar{x}_{m,B \rightarrow A}}{\gamma_m \psi_{m,B \rightarrow A}} + \bar{x}_{m,B \rightarrow A} \\ &= \frac{\bar{x}_{m,B \rightarrow A} + \psi_{m,B \rightarrow A} \mathbf{h}_m^H \boldsymbol{\Omega}^{-1} \check{\mathbf{y}} - \bar{x}_{m,B \rightarrow A}}{\gamma_m \psi_{m,B \rightarrow A}} + \bar{x}_{m,B \rightarrow A} \\ &= \bar{x}_{m,B \rightarrow A} + \frac{1}{\gamma_m} \mathbf{h}_m^H \boldsymbol{\Omega}^{-1} \check{\mathbf{y}}\end{aligned}\quad (33)$$

外部分布  $f_{A \rightarrow B}(\tilde{x}_m)$  の

期待値  $\mathbb{E}_{f_{A \rightarrow B}}\{\tilde{x}_m\} = \bar{x}_{m,A \rightarrow B}$  と分散値  $\mathbb{V}_{f_{A \rightarrow B}}\{\tilde{x}_m\} = \psi_{m,A \rightarrow B}$

$$\bar{x}_{m,A \rightarrow B} = \bar{x}_{m,B \rightarrow A} + \frac{1}{\gamma_m} \mathbf{h}_m^H \boldsymbol{\Omega}^{-1} \check{\mathbf{y}}\quad (34)$$

$$\psi_{m,A \rightarrow B} = \frac{1}{\gamma_m} - \psi_{m,B \rightarrow A}\quad (35)$$

### 3. モジュール B の事後分布 $f_B(\tilde{x}_m)$

モジュール B における真の事後分布  $p_B(\tilde{x}_m)$

ベイズ則に基づき,

$$p_B(\tilde{x}_m) \propto f_{A \rightarrow B}(\tilde{x}_m) \cdot p(\tilde{x}_m) \quad (36)$$

- 送信シンボル  $x_m$  が離散値  $\Rightarrow$  事前分布  $p(\tilde{x}_m)$  が等確率のデルタ関数
- デルタ関数の性質により, 真の事後分布  $p_B(\tilde{x}_m)$  から算出される期待値  $\mathbb{E}_{p_B}\{\tilde{x}_m\} = \bar{x}_{m,B}$  と分散値  $\mathbb{V}_{p_B}\{\tilde{x}_m\} = \psi_{m,B}$  が次式となる.

$$\bar{x}_{m,B} = \sum_{\chi_q} \chi_q \frac{f_{A \rightarrow B}(\chi_q)}{\sum_{\chi'_q} f_{A \rightarrow B}(\chi'_q)} = \sum_{q=1}^Q \chi_q \eta_q(\beta_m) \quad (37)$$

$$\psi_{m,B} = \sum_{q=1}^Q |\chi_q|^2 \eta_q(\beta_m) - |\bar{x}_{m,B}|^2 \quad (38)$$

ただし,

$$\beta_m = [\beta_{m,1}, \dots, \beta_{m,q}, \dots, \beta_{m,Q}] \quad (39)$$

$$\beta_{m,q} = -\frac{|\chi_q - \bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \quad (40)$$

### 3. モジュール B の事後分布 $f_B(\tilde{x}_m)$

#### 扱いやすい事後分布 $f_B(\tilde{x}_m)$

- 独立なモジュール A と B の外部分布の積

$$f_B(\tilde{x}_m) \propto f_{A \rightarrow B}(\tilde{x}_m) \cdot f_{B \rightarrow A}(\tilde{x}_m) \quad (41)$$

- ここで、扱いやすい事後分布  $f_B(\tilde{x}_m)$  の 2 次モーメントまで（つまり期待値と分散値）を  $\bar{x}_{m,B}$  と  $\psi_{m,B}$  に一致させる「積率整合」を満たすように  $f_{B \rightarrow A}(\tilde{x}_m)$  を設定
- さらに、 $f_{B \rightarrow A}(\tilde{x}_m)$  がガウス分布に従うものとする、 $f_B(\tilde{x}_m)$  もガウス分布  $CN(\bar{x}_{m,B}, \psi_{m,B})$  に従う。

## 4. モジュール B の外部分布 $f_{B \rightarrow A}(\tilde{x}_m)$

### 積率整合を満たす外部分布 $f_{B \rightarrow A}(\tilde{x}_m)$

- 事後分布  $f_B(\tilde{x}_m)$  から事前分布  $f_{A \rightarrow B}(\tilde{x}_m)$  の影響を独立化  $\Rightarrow$  除算

$$f_{B \rightarrow A}(\tilde{x}_m) \propto \frac{f_B(\tilde{x}_m)}{f_{A \rightarrow B}(\tilde{x}_m)} \propto \exp \left[ - \left\{ \frac{|\tilde{x}_m - \bar{x}_{m,B}|^2}{\psi_{m,B}} - \frac{|\tilde{x}_m - \bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \right\} \right] \quad (42)$$

- 外部分布  $f_{B \rightarrow A}(\tilde{x}_m)$  も期待値  $\bar{x}_{m,B \rightarrow A}$  と分散値  $\psi_{m,B \rightarrow A}$  を持つガウス分布に従う。

$$f_{B \rightarrow A}(\tilde{x}_m) \sim \mathcal{CN}(\bar{x}_{m,B \rightarrow A}, \psi_{m,B \rightarrow A}) \propto \exp \left[ - \frac{|\tilde{x}_m - \bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}} \right] \quad (43)$$

## 4. モジュール B の外部分布 $f_{B \rightarrow A}(\tilde{x}_m)$

- 式 (42) を展開し、式 (43) と比較すると、

外部分布  $f_{B \rightarrow A}(\tilde{x}_m)$  の

期待値  $\mathbb{E}_{f_{B \rightarrow A}}\{\tilde{x}_m\} = \bar{x}_{m,B \rightarrow A}$  と分散値  $\mathbb{V}_{f_{B \rightarrow A}}\{\tilde{x}_m\} = \psi_{m,B \rightarrow A}$

$$\psi_{m,B \rightarrow A} = \frac{\psi_{m,B} \cdot \psi_{m,A \rightarrow B}}{\psi_{m,A \rightarrow B} - \psi_{m,B}} \quad (44)$$

$$\bar{x}_{m,B \rightarrow A} = \psi_{m,B \rightarrow A} \left( \frac{\bar{x}_{m,B}}{\psi_{m,B}} - \frac{\bar{x}_{m,A \rightarrow B}}{\psi_{m,A \rightarrow B}} \right) \quad (45)$$

ただし、例外処理として  $\psi_{m,A \rightarrow B} < \psi_{m,B}$  となる場合には、外部分布  $f_{B \rightarrow A}(\tilde{x}_m)$  を用いずに事後分布  $f_B(\tilde{x}_m)$  をそのままモジュール A にフィードバックするものとする。

# 補足

$$\begin{aligned}
 & \frac{|\tilde{x}_m - \bar{x}_{m,B}|^2}{\psi_{m,B}} - \frac{|\tilde{x}_m - \bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \\
 = & \frac{|\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,B}\} + |\bar{x}_{m,B}|^2}{\psi_{m,B}} - \frac{|\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,A \rightarrow B}\} + |\bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B}} \\
 = & \frac{\psi_{m,A \rightarrow B} (|\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,B}\} + |\bar{x}_{m,B}|^2)}{\psi_{m,B} \psi_{m,A \rightarrow B}} \\
 & - \frac{\psi_{m,B} (|\tilde{x}_m|^2 - 2\Re\{\tilde{x}_m \bar{x}_{m,A \rightarrow B}\} + |\bar{x}_{m,A \rightarrow B}|^2)}{\psi_{m,B} \psi_{m,A \rightarrow B}} \\
 = & \frac{(\psi_{m,A \rightarrow B} - \psi_{m,B}) |\tilde{x}_m|^2 - 2\Re\{(\psi_{m,A \rightarrow B} \bar{x}_{m,B} - \psi_{m,B} \bar{x}_{m,A \rightarrow B}) \tilde{x}_m\}}{\psi_{m,B} \psi_{m,A \rightarrow B}} \\
 & + \frac{\psi_{m,A \rightarrow B} |\bar{x}_{m,B}|^2 - \psi_{m,B} |\bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,B} \psi_{m,A \rightarrow B}} \\
 = & \frac{|\tilde{x}_m|^2 - \frac{2\Re\{(\psi_{m,A \rightarrow B} \bar{x}_{m,B} - \psi_{m,B} \bar{x}_{m,A \rightarrow B}) \tilde{x}_m\}}{\psi_{m,A \rightarrow B} - \psi_{m,B}} + \frac{\psi_{m,A \rightarrow B} |\bar{x}_{m,B}|^2 - \psi_{m,B} |\bar{x}_{m,A \rightarrow B}|^2}{\psi_{m,A \rightarrow B} - \psi_{m,B}}}{\frac{\psi_{m,B} \psi_{m,A \rightarrow B}}{\psi_{m,A \rightarrow B} - \psi_{m,B}}}
 \end{aligned} \tag{46}$$

# 補足

$$\begin{aligned}
 f_{B \rightarrow A}(\tilde{x}_m) &\propto \exp \left[ -\frac{|\tilde{x}_m - \bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}} \right] \\
 &= \exp \left[ -\frac{|\tilde{x}_m|^2 - 2\Re\{\bar{x}_{m,B \rightarrow A} \tilde{x}_m\} + |\bar{x}_{m,B \rightarrow A}|^2}{\psi_{m,B \rightarrow A}} \right] \quad (47)
 \end{aligned}$$

と比較して,

$$\begin{aligned}
 \psi_{m,B \rightarrow A} &= \frac{\psi_{m,B} \psi_{m,A \rightarrow B}}{\psi_{m,A \rightarrow B} - \psi_{m,B}} \Rightarrow \frac{1}{\psi_{m,A \rightarrow B}} = \frac{1}{\psi_{m,B}} - \frac{1}{\psi_{m,A \rightarrow B}} \quad (48) \\
 \bar{x}_{m,B \rightarrow A} &= \frac{\psi_{m,A \rightarrow B} \bar{x}_{m,B} - \psi_{m,B} \bar{x}_{m,A \rightarrow B}}{\psi_{m,A \rightarrow B} - \psi_{m,B}} \\
 &= \frac{\psi_{m,B} \psi_{m,A \rightarrow B}}{\psi_{m,A \rightarrow B} - \psi_{m,B}} \cdot \frac{\psi_{m,A \rightarrow B} \bar{x}_{m,B} - \psi_{m,B} \bar{x}_{m,A \rightarrow B}}{\psi_{m,B} \psi_{m,A \rightarrow B}} \\
 &= \psi_{m,B \rightarrow A} \left( \frac{\bar{x}_{m,B}}{\psi_{m,B}} - \frac{\bar{x}_{m,A \rightarrow B}}{\psi_{m,B \rightarrow A}} \right) \quad (49)
 \end{aligned}$$

# EP アルゴリズム (まとめ)

---

## Algorithm 1 EP algorithm

---

**Input:**  $\mathbf{y}, \mathbf{H}, N_0$

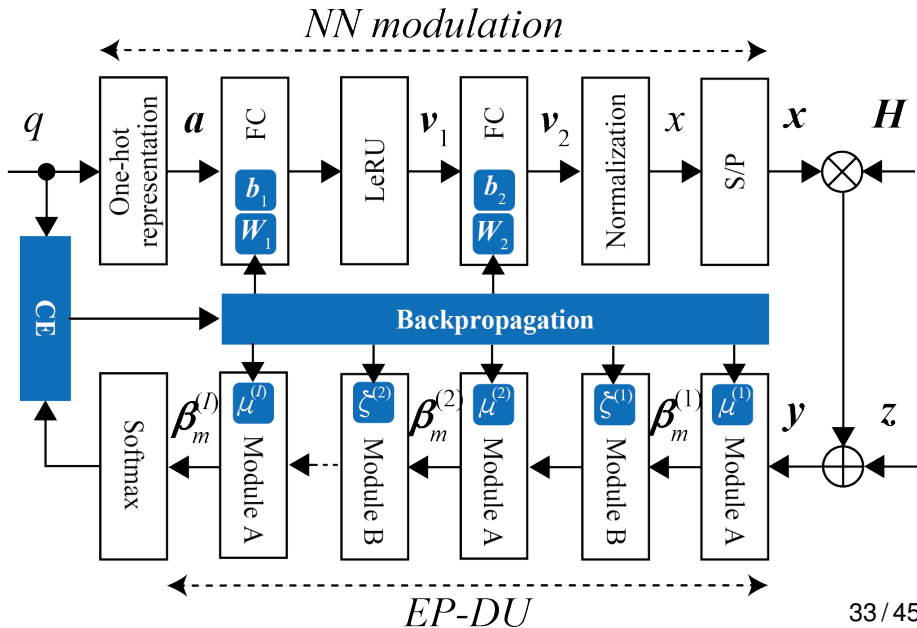
**Output:**  $\forall m: \hat{\mathbf{x}}_m$

- 1:  $\forall m$ : Initialize  $\bar{\mathbf{x}}_{m,B \rightarrow A}^{(0)} = \mathbf{0}, \psi_{m,B \rightarrow A}^{(0)} = \mathbf{E}_S$
- 2: **for**  $i = 1$  to  $I + 1$  **do**
  - /\* Module A \*/
  - 3:  $\check{\mathbf{y}}^{(i)} = \mathbf{y} - \sum_{m=1}^M \mathbf{h}_m \bar{\mathbf{x}}_{m,B \rightarrow A}^{(i-1)}$
  - 4:  $\boldsymbol{\Omega}^{(i)} = \sum_{m=1}^M \mathbf{h}_m \psi_{m,B \rightarrow A}^{(i-1)} \mathbf{h}_m^H + N_0 \mathbf{I}_N$
  - 5: **if**  $i = I + 1$  **then**
    - 6: **break**
  - 7: **end if**
  - 8:  $\forall m: \gamma_m^{(i)} = \mathbf{h}_m^H [\boldsymbol{\Omega}^{(i)}]^{-1} \mathbf{h}_m$
  - 9:  $\forall m: \bar{\mathbf{x}}_{m,A \rightarrow B}^{(i)} = \bar{\mathbf{x}}_{m,B \rightarrow A}^{(i-1)} + \frac{1}{\gamma_m^{(i)}} \mathbf{h}_m^H [\boldsymbol{\Omega}^{(i)}]^{-1} \check{\mathbf{y}}^{(i)}$
  - 10:  $\forall m: \psi_{m,A \rightarrow B}^{(i)} = \frac{1}{\gamma_m^{(i)}} - \psi_{m,B \rightarrow A}^{(i-1)}$

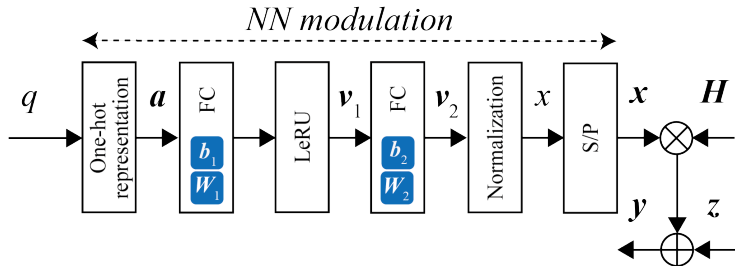
- /\* Module B \*/
  - 11:  $\forall (m, q): \beta_{m,q}^{(i)} = - \frac{|\chi_q - \bar{\mathbf{x}}_{m,A \rightarrow B}^{(i)}|^2}{\psi_{m,A \rightarrow B}^{(i)}}$
  - 12:  $\forall m: \boldsymbol{\beta}_m^{(i)} = [\beta_{m,1}^{(i)}, \dots, \beta_{m,Q}^{(i)}]$
  - 13:  $\forall m: \bar{\mathbf{x}}_{m,B}^{(i)} = \sum_{q=1}^Q \chi_q \eta_q (\boldsymbol{\beta}_m^{(i)})$
  - 14:  $\forall m: \psi_{m,B}^{(i)} = \sum_{q=1}^Q |\chi_q|^2 \eta_q (\boldsymbol{\beta}_m^{(i)}) - |\bar{\mathbf{x}}_{m,B}^{(i)}|^2$
  - 15:  $\forall m: \psi_{m,B \rightarrow A}^{(i+1)} = \frac{\psi_{m,B}^{(i)} \psi_{m,A \rightarrow B}^{(i)}}{\psi_{m,A \rightarrow B}^{(i)} \psi_{m,B}^{(i)} - \psi_{m,B}^{(i)}}$
  - 16:  $\forall m: \bar{\mathbf{x}}_{m,B \rightarrow A}^{(i+1)} = \psi_{m,B \rightarrow A}^{(i+1)} \left( \frac{\bar{\mathbf{x}}_{m,B}^{(i)}}{\psi_{m,B}^{(i)}} - \frac{\bar{\mathbf{x}}_{m,A \rightarrow B}^{(i)}}{\psi_{m,A \rightarrow B}^{(i)}} \right)$
  - 17: **end for**
    - /\* Terminate \*/
    - 18:  $\forall m: \bar{\mathbf{x}}_{m,A} = \bar{\mathbf{x}}_{m,B \rightarrow A}^{(I+1)} + \psi_{m,B \rightarrow A}^{(I+1)} \mathbf{h}_m^H [\boldsymbol{\Omega}^{(I+1)}]^{-1} \check{\mathbf{y}}^{(I+1)}$
    - 19:  $\forall m: \hat{\mathbf{x}}_m = \arg \min_{\chi_q \in \mathcal{X}} |\chi_q - \bar{\mathbf{x}}_{m,A}|^2$
-

- 1 無線物理層への AI(深層学習) の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

# 自己符号化器の構成



# NN 変調器




- 入力層：ビット系列を  $Q$  値の整数記号  $q \in \{0, \dots, Q-1\}$  に変換  
 $\Rightarrow Q$  次元ワンホットベクトル  $a$  に変換
- 全結合層： $W_1 \in \mathbb{R}^{D \times Q}$  と  $b_1 \in \mathbb{R}^{D \times 1}$  で構成  $\Rightarrow W_1 a + b_1$
- LeRU(活性化関数)： $v_1 = \max(W_1 a + b_1, 0)$
- 全結合層： $W_2 \in \mathbb{R}^{2 \times D}$  と  $b_2 \in \mathbb{R}^{2 \times 1}$  で構成  $\Rightarrow v_2 = W_2 v_1 + b_2$
- 正規化層： $v_2 = [v_{2,1}, v_{2,2}]^T$  の中心化および電力調整

$$x = \alpha (\tilde{v}_{2,1} + j\tilde{v}_{2,2}), \quad \tilde{v}_{2,l} = v_{2,l} - \mathbb{E}\{v_{2,l}\}, \quad \alpha = \sqrt{\frac{E_s}{\mathbb{E}\{\tilde{v}_{2,1}^2 + \tilde{v}_{2,2}^2\}}} \quad (50)$$

$\Rightarrow$  複素数のベクトル  $x$  に変換

# EP-DU 検出器




## モジュール A：スケーリング

$$\psi_{m,A \rightarrow B}^{(i)} \leftarrow \frac{\psi_{m,A \rightarrow B}^{(i)}}{\mu^{(i)}} \quad (51)$$

- モジュール A の外部分布の分散の近似誤差を緩和するスケーリングパラメータ  $\mu^{(i)}$  ← 深層展開の学習可能パラメータにする。

# EP-DU 検出器



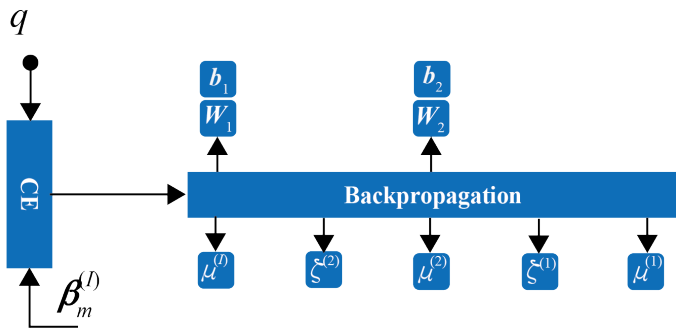
## モジュール B：ダンピング

$$\psi_{m,B \rightarrow A}^{(i)} = \zeta^{(i)} \left[ \frac{\psi_{m,B}^{(i)} \cdot \psi_{m,A \rightarrow B}^{(i)}}{\psi_{m,A \rightarrow B}^{(i)} - \psi_{m,B}^{(i)}} \right] + (1 - \zeta^{(i)}) \psi_{m,B \rightarrow A}^{(i-1)} \quad (52)$$

$$\bar{x}_{m,B \rightarrow A}^{(i)} = \zeta^{(i)} \left[ \psi_{m,B \rightarrow A}^{(i)} \left( \frac{\bar{x}_{m,B}^{(i)}}{\psi_{m,B}^{(i)}} - \frac{\bar{x}_{m,A \rightarrow B}^{(i)}}{\psi_{m,A \rightarrow B}^{(i)}} \right) \right] + (1 - \zeta^{(i)}) \bar{x}_{m,B \rightarrow A}^{(i-1)} \quad (53)$$

- 期待値と分散値の急激な変化を抑えるダンピングパラメータ  $\zeta^{(i)}$   
 $\leftarrow$  深層展開の学習可能パラメータに

# 学習可能パラメータの最適化




損失関数（交差エントロピー）最小化するモデルベース最適化

$$E(W_1, W_2, b_1, b_2, \mu^{(1)}, \dots, \mu^{(l)}, \zeta^{(1)}, \dots, \zeta^{(l)}) = -\sum_{q=1}^Q a_q \ln(\eta_q(\beta^{(l)}))$$


- NN 変調器および EP-DU の繰り返し構造を FFNN と見做す
- 誤差逆伝播法 (Backpropagation)
- 確率的勾配降下法の Adam (Adaptive moment) の最適化アルゴリズム

# 学習手順（生成的アプローチ）



- 1 Optuna では  $\text{tr } E_s/N_0$  をハイパーパラメータとして、初期値を乱数で決定
- 2 与えられた  $\text{tr } E_s/N_0$  で、エポック数を  $10^5$ 、学習率を 0.005 として、学習可能パラメータ  $\Theta = \{W_1, W_2, b_1, b_2, \mu^{(i)}, \zeta^{(i)}\}$  を学習 (Train)  
※各エポックでは、バッチサイズを 10 送信ベクトル  $x$  として送信し、異なる  $H$  を用いて CE を求め、汎化性能を高めた。
- 3 得られた学習可能パラメータ  $\Theta$  を用いて、 $E_s/N_0$  に対する SER 特性を求めるテスト (Test) を行い、 $\text{SER}=10^{-3}$  を満たす最小のテスト  $E_s/N_0$  の値を探索

# 学習手順 (生成的アプローチ)



- ④  $SER=10^{-3}$  を満たす最小のテスト  $E_s/N_0$  の値の最小化を行うように Optuna によるベイズ最適化を行い、ハイパーパラメータ  $\text{tr} E_s/N_0$  を調整
- ⑤ ベイズ最適化の試行回数は  $10^3$  とする。その試行の中で、 $SER=10^{-3}$  を満たす最も低いテスト  $E_s/N_0$  を達成したときの、学習可能パラメータ  $\theta$  を WAE 内の学習済みパラメータとする。

要するに、

$SER=10^{-3}$  を最も低い  $E_s/N_0$  で達成する学習可能パラメータ  $\theta$  を生成




- 1 無線物理層への AI(深層学習) の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

# 計算機シミュレーション




## シミュレーション諸元

送受信アンテナ数 $[M, N]$	[16,16]
変調多値数 $Q$	16, 64, 256
中間層のノード数 $D$	512
EP の繰り返し回数 $I$	8
通信路	レイリーフェージング (通信路推定は完全)
学習率	0.005
勾配アルゴリズム	Adam
エポック数	$10^5$
ミニバッチサイズ	10

# 自己符号化器の学習結果






(a)  $Q=16$



(b)  $Q=64$

# 自己符号化器の学習結果




(c)  $Q=256$

## 信号点配置の形状から

- 傾向を直感的に理解することができないものの，設定した損失関数の最小化を実現するものとして機械が選び出したものである。

# シンボル誤り率特性



- “w/ NN”：学習済 NN 変調器，“w/o NN”：QAM
- “w/ DU”：学習済 EP-DU，“w/o DU”： $\mu^{(i)} = 1, \zeta^{(i)} = 0$

改善 ( $E_s/N_0$  低減) 効果@SER =  $10^{-3}$

- “w/o DU” で NN の有無  $\Rightarrow Q = [16, 64, 256] : [3.54, 3.34, 2.93]$  dB
- “w/o NN” で DU の有無  $\Rightarrow Q = [16, 64, 256] : [7.05, 5.60, 2.38]$  dB
- NN と DU 併用の有無  $\Rightarrow Q = [16, 64, 256] : [7.81, 8.90, 8.57]$  dB

# アウトライン

- 1 無線物理層への AI(深層学習) の導入レベル
- 2 信号点配置とシンボル誤り率
  - デジタル通信システム
- 3 最大事後確率検出
  - 多次元信号検出
  - 最大事後確率規範
- 4 期待値伝搬法
  - 繰り返し検出
  - モジュール A
  - モジュール B
- 5 自己符号化器の構成
  - NN 変調器
  - EP-DU 検出器
  - 学習可能パラメータの最適化
- 6 計算機シミュレーション
  - 自己符号化器の学習結果
  - シンボル誤り率特性
- 7 まとめ

# まとめ

## 背景：素朴な疑問

- MIMO 信号検出に繰り返し信号検出を使いたい！
- 「本当に、信号点のユークリッド距離の最大化が有効なのか？」

## 着眼点：無線物理層への深層学習の導入レベル

- 【Lv0】モデル駆動アプローチと【Lv1】モデルベース深層学習（DU）の検討を発展させたい
- 【Lv2】モデルベース深層学習（WAE）をデザインした！

## 提案：自己符号化器

- 受信機は EP の深層展開，送信機はシンプルな NN で構成
- 正規化に工夫が必要，LLV への制約も重要，NN の初期値依存性にも配慮 ←（ある意味，「職人技」が求められる。）
- シンボル誤り率の観点から有効性を確認