

制限付きベイジアンネット BESOM における認識アルゴリズム OOBP

人工知能学会全国大会 JSAI2014

オーガナイズドセッション:

3H4-OS-24b「OS-24 Deep Learning (2)」

<https://kaigi.org/jsai/webprogram/2014/paper-373.html>

2014-05-14

産業技術総合研究所

一杉裕志、高橋直人

発表の流れ

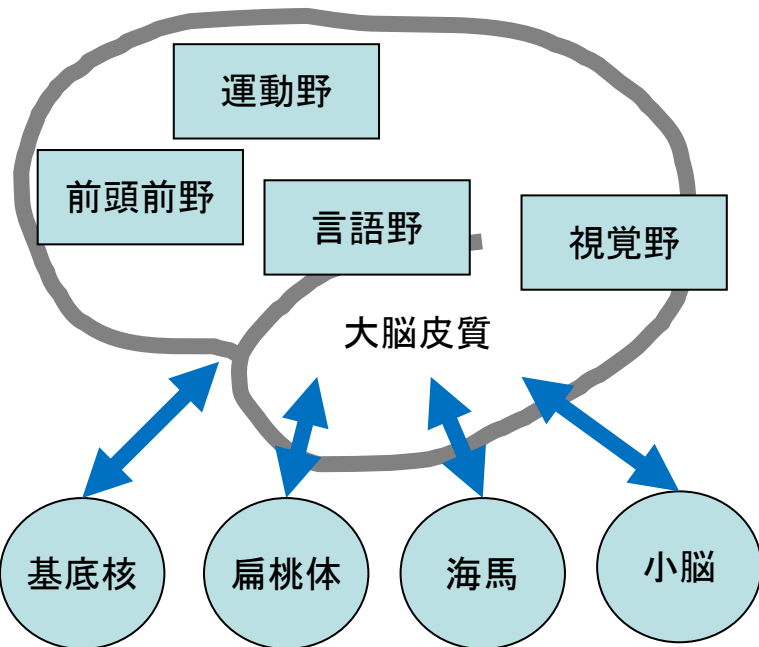
- 背景：
 - 神経科学的知見は、大脳皮質は Deep Learning と同じ構造のベイジアンネットであると示唆。
- ベイジアンネットを用いた Deep Learning の工学的な有望さ
- 計算量の問題の解決案：条件付確率の制約
- 現段階での性能評価
- 今後

私の研究の目的

- 人間のように知能の高いロボットを作って、社会の生産性を飛躍的に向上させ、人々の生活をより豊かにすること。
- 役に立つロボットに必要な能力：
 - **自律学習**: 赤ん坊のように自分で知識を獲得
 - **自律行動**: 新たな状況でも自分で考えて行動
 - **言語理解**: 自然言語を通じた意思の疎通
- そのための近道として、まず脳全体のアーキテクチャを解明すべき。

脳の各組織のモデル

脳を構成する主要要素



脳の各組織の機械学習装置としてのモデル

大脳皮質: SOM、ICA、ベイジアンネットワーク

大脳基底核、扁桃体: 強化学習

小脳: パーセプトロン、リキッドステートマシン

海馬: 自己連想ネットワーク

主な領野の情報処理装置としての役割


視覚野: deep learning

運動野: 階層型強化学習

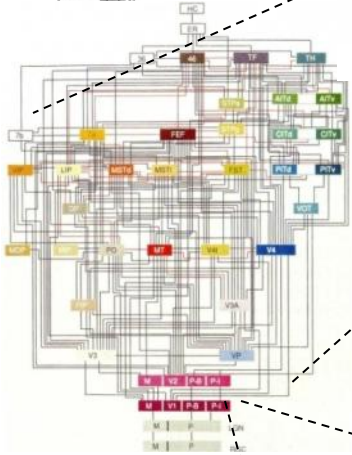
前頭前野: 状態遷移機械?

言語野: チャートパーサ?


大脳皮質




Wikipedia より




Daniel J. Felleman and David C. Van Essen
Distributed Hierarchical Processing in the Primate
Cerebral Cortex
Cerebral Cortex 1991 1: 1-47



厚さ約2ミリ



I
II
III
IV
V
VI



- 脳の様々な高次機能（認識、意思決定、運動制御、思考、推論、言語理解など）が、**たった50個程度**の領野のネットワークで実現されている。

Deep Learning の源流

Neocognitron [Fukushima 1980]

当時の視覚野の知見をもとに作られた、実際に手書き文字認識を行うモデル。
たたみ込みNNと同じ構造を持つ。




Fig. 1. Correspondence between the hierarchy model by Hubel and Wiesel, and the neural network of the neocognitron




Fig. 2. Schematic diagram illustrating the interconnections between layers in the neocognitron





Fig. 6. Some examples of distorted stimulus patterns which the neocognitron has correctly recognized, and the response of the final layer of the network

K. Fukushima. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4): 93-202, 1980.

大脳皮質にみられる階層的構造


脳はおそらく様々な情報処理に Deep Learning を用いている。



ベイジアンネットを使った大脳皮質モデル

- 視覚野の機能、運動野の機能、解剖学的構造、電気生理学的現象などを説明
 - [Lee and Mumford 2003]
 - [George and Hawkins 2005]
 - [Rao 2005]
 - [Ichisugi 2007] [Ichisugi 2010] [Ichisugi 2011] [Ichisugi 2012]
 - [Rohrbein, Eggert and Korner 2008]
 - [Hosoya 2009] [Hosoya 2010] [Hosoya 2012]
 - [Litvak and Ullman 2009]
 - [Chikkerur, Serre, Tan and Poggio 2010]
 - [Hasegawa and Hagiwara 2010]
 - [Dura-Bernal, Wennekers, Denham 2012]

Deep Learning と同じ構造をしたベイジアンネットによる視覚野の模式図



ベイジアンネットを使った Deep Learning が有望と考える理由

- 「制約付きベイジアンネット」であれば、1入力あたりの認識・学習の計算量が大きくない。
 - 大規模化可能 将来的には100万ノード規模
- Feed forward NN より高機能。
 - 文脈の情報が自然に扱える。
 - 半教師あり学習、欠損データの学習が自然に扱える。
- 生成モデルを素直に表現可能。
 - 様々な事前知識を作り込みやすい。
 - 神経科学的知見からも作り込むべき事前知識のヒントが得られる。(ネットワークトポロジやハイパパラメタ)

BESOM (Bidirectional SOM) とは？

- 大脳皮質ベイジアンネットモデルの1つ。
- ベイジアンネットと Deep Learning と SOM と ICA を組み合わせた機械学習アルゴリズム。
 - **ただし未完成な技術。**
- 目指す目標：
 - 計算量に関するスケーラビリティ **今回の発表**
 - 精度のスケーラビリティ(次元の呪いの克服)
 - 機械学習理論的妥当性
 - 神経科学的妥当性

BESOM Ver.3.0 の機構

- 制限付きの条件付確率表のモデル
- 認識・学習アルゴリズム

- 正則化


- 近傍学習
- 勝率ペナルティ
- 側抑制ICA
- エッジ選択

本発表では割愛

条件付確率表のモデルの制限

- 一般に親ノードの数 m 個に対して $O(2^m)$ のサイズが必要。→ メモリ・計算量が爆発
- そこで条件付確率表を下記の形に制限。

$$P(x|u_1, \dots, u_m) = \frac{1}{m} \sum_{k=1}^m P(x|u_k)$$



条件付確率表の制限の 生物学的根拠


1. 一次視覚野のスパースコーディングモデル

[Olshausen and Field 1996]

基底画像の線形和で入力画像を表現、ニューロンの
応答特性をうまく再現

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t)$$

2. 線形和を仮定した近似確率伝搬アルゴリズム が大脳皮質の解剖学的構造と類似 [Ichisugi 2007]



学習の目的

- 学習の目的:
 - 時刻 t における入力を $\mathbf{i}(t)$ と、入力が独立同分布 (i.i.d) から生成されると仮定して、パラメタ θ を MAP 推定

$$\begin{aligned}\theta^* &= \arg \max_{\theta} \left[\prod_{i=1}^t P(\mathbf{i}(i) | \theta) \right] P(\theta) \\ &= \arg \max_{\theta} \left[\prod_{i=1}^t \sum_{\mathbf{h}} P(\mathbf{h}, \mathbf{i}(i) | \theta) \right] P(\theta)\end{aligned}$$

オンラインEM(と思われるもの)の動作


- 入力 $\mathbf{i}(t)$ ごとに、親子ノード間の条件付きの事後確率分布 $P(y_j | x_i, \mathbf{i}(t); \theta(t))$ を推定。
- それを真の値とみなしてパラメタ θ を更新。
- 事後確率分布の推定には Loopy BP のメッセージ収束結果を利用。

$$\begin{aligned} P(y_j | x_i, \mathbf{i}(t); \theta(t)) \\ = \alpha \lambda(y_j) P(y_j | x_i) \pi_Y(x_i) / BEL(x_i) \end{aligned}$$

特殊なケースについては、この式が正しいことを確認している。
一般にも成り立つかどうかは未確認。

条件付きの事後確率分布の推定の例

$$P(a, b, c, d) = P(d|c)P(c|b)P(b|a)P(a)$$



$$\begin{aligned} P(b, c|d) &= \alpha \sum_a P(d|c)P(c|b)P(b|a)P(a) \\ &= \alpha P(d|c) P(c|b) \{ \sum_a P(b|a)P(a) \} \\ &= \alpha \lambda(c)P(c|b) \pi_C(b) \end{aligned}$$

$$\begin{aligned} P(c|b, d) &= P(b, c, d)/P(b, d) \\ &= \{P(b, c|d)P(d)\}/\{P(b|d)P(d)\} \\ &= P(b, c|d)/P(b|d) \\ &= \alpha \lambda(c)P(c|b) \pi_C(b) /BEL(b) \end{aligned}$$

D=d を観測値とする

認識アルゴリズム OOBP

(Optimized Original
Belief Propagation)

Belief Propagation [Pearl 1988]

$$\begin{aligned}BEL(x) &= \alpha \lambda(x) \pi(x) \\ \pi(x) &= \sum_{u_1, \dots, u_m} P(x|u_1, \dots, u_m) \prod_k \pi_X(u_k) \\ \lambda(x) &= \prod_l \lambda_{Y_l}(x) \\ \pi_{Y_l}(x) &= \beta_1 \pi(x) \prod_{j \neq l} \lambda_{Y_j}(x) \\ \lambda_X(u_k) &= \beta_2 \sum_x \lambda(x) \\ &\quad \sum_{u_1, \dots, u_m / u_k} P(x|u_1, \dots, u_m) \prod_{i \neq k} \pi_X(u_i)\end{aligned}$$

OOBP

$$\begin{aligned}\lambda_{Y_l}^{t+1}(x) &= \beta_2 \sum_{y_l} \lambda^t(y_l) (\pi^t(y_l) - \kappa_X^t(y_l) + w(y_l, x)) \\ \lambda^{t+1}(x) &= \prod_{l=1}^n \lambda_{Y_l}^{t+1}(x) \\ \pi_{Y_l}^{t+1}(x) &= \beta_1 \rho^{t+1}(x) / \lambda_{Y_l}^{t+1}(x) \\ \kappa_{U_k}^{t+1}(x) &= \sum_{u_k} w(x, u_k) \pi_X^t(u_k) \\ \pi^{t+1}(x) &= \sum_{k=1}^m \kappa_{U_k}^{t+1}(x) \\ \rho^{t+1}(x) &= \lambda^{t+1}(x) \pi^{t+1}(x) \\ BEL^{t+1}(x) &= \alpha \rho^{t+1}(x)\end{aligned}$$

親ノードの数 m に対し
 $O(2^m)$ の計算量

制限された条件付確
率表のモデルを
前提に最適化

$O(m)$ の計算量

$$P(x|u_1, \dots, u_m) = \frac{1}{m} \sum_{k=1}^m P(x|u_k)$$

計算時間の評価


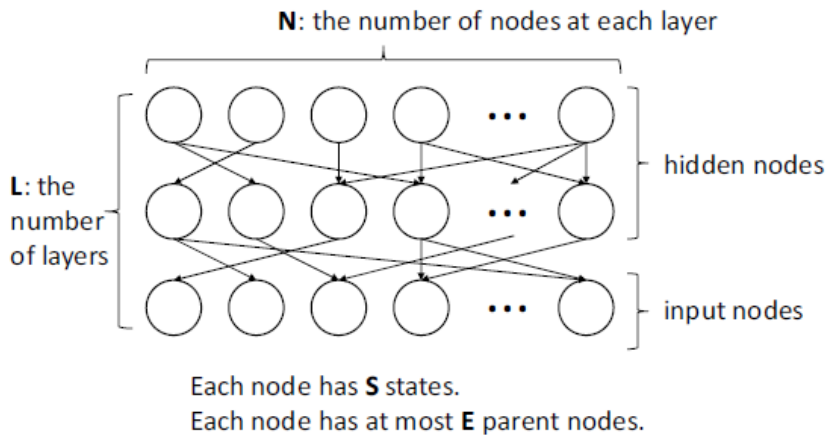


図 1: 計算量評価に用いたネットワークの構造

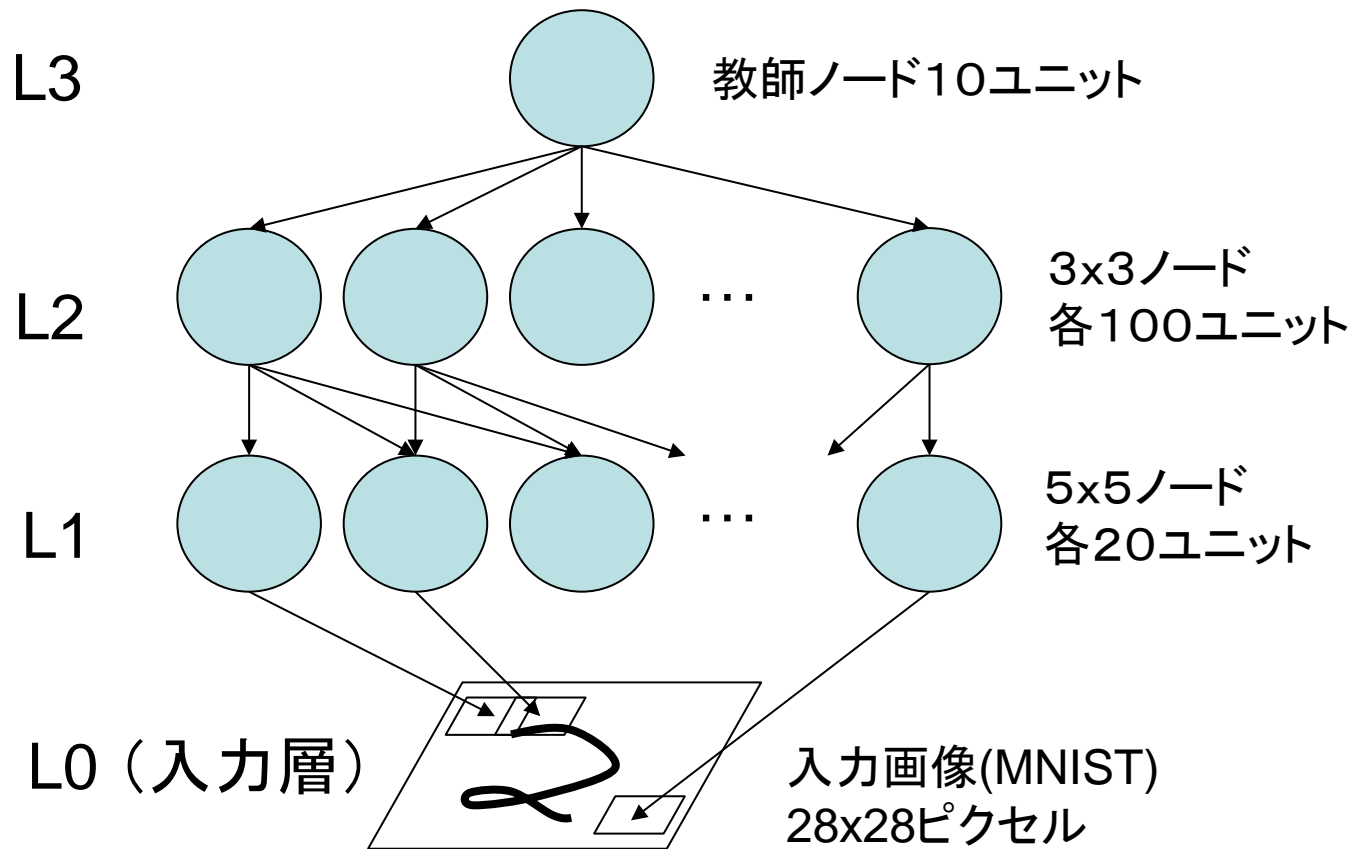
図 2: OOBP の実行時間

レイヤ数 $L=4$ 、各レイヤのノード数 $N=100$ 、各ノードの状態数 $S=4$ 親ノードの数 E を変化させて10回のメッセージ伝搬の計算時間を、ネットワークトポロジと条件付確率をランダムに変えて100回計測した平均。

最適化前の Loopy Belief Propagation の素朴な実装では $E=4$ で計測不能に。

$E=1$: 137ms, $E=2$: 2,620ms, $E=3$: 28,223ms

4層 制限付きベイジアンネットワーク 手書き数字認識



pre-training なし、認識アルゴリズムは
OOBP、EMアルゴリズムで学習
認識率: 91%程度

参考:
linear classifier (1-layer NN) 88%
Ciresan et al. CVPR 2012 99.87%
「MNIST handwritten digit database」
<http://yann.lecun.com/exdb/mnist/>

現在、正則化の機構は EM に未対応

	MPE学習	オンラインEM
基本的な認識と学習	実装済み	実装済み
近傍学習	実装済み	未対応
勝率ペナルティ	実装済み	未対応
側抑制ICA	実装済み	未対応
エッジ選択	実装済み	未対応
運動野モデル	実装済み	未対応



すべて EM に対応することで
精度を上げる余地がある。

大脳皮質ベイジアンネットワークモデルの 先行研究

- [George and Hawkins 2005] HTM
 - Tree 構造に限定。
 - アドホックな学習則。
- [Hosoya 2012]
 - Softmax を用いた条件付確率表モデル。
 - MCMC を使った学習。
- [Dura-Bernal, Wennekers, Denham 2012]
 - 本研究と似た線形和の条件付確率表モデル。
 - アドホックな学習則。

まとめ

- 神経科学的知見は、大脳皮質は Deep Learning と同じ構造のベイジアンネットであると示唆。
- ベイジアンネットを用いた Deep Learning は工学的にも有望。
- ベイジアンネットの条件付確率表に制限を入れ、確率伝搬アルゴリズムを最適化することで、Deep Learning を**実現可能であることを示した**。
- 現在、実装は未完成のため性能は不十分。
 - 今後実装を完成させ、より厳密な性能評価へ。

全脳アーキテクチャ勉強会

- 第1回 2013年12月 **開催趣旨説明** 約100名参加
 - － 講演者：産総研 一杉裕志、東大 松尾豊、富士通研 山川宏
- 第2回 1月**「大脳皮質と Deep Learning」** 約250名参加
 - － 講演者：産総研 一杉裕志、筑波大学 酒井宏、PFI 得居誠也
- 第3回 4月**「海馬とSLAM」** 約200名参加
 - － 講演者：はこだて未来大 佐藤直行、産総研 横塚将志、富士通研 山川宏
- 第4回 6月2日(月) **関西編** 大阪府吹田市
 - － 講演者：産総研 一杉裕志、東大 松尾豊、富士通研 山川宏、NICT CiNet 西本伸志、理研 泰地真弘

全脳アーキテクチャ

検索

追加資料

Generic Priors for Disentangling Factors of Variation

[Bengio 2013] <http://arxiv.org/abs/1305.0445>

Yoshua Bengio,
Deep Learning of Representations: Looking Forward,
Statistical Language and Speech Processing,
Lecture Notes in Computer Science Volume 7978, 2013, pp 1-37
http://link.springer.com/chapter/10.1007%2F978-3-642-39593-2_1#

- Smoothness
- Multiple explanatory factors
- A hierarchical organization of explanatory factors
- Semi-supervised learning
- Shared factors across tasks
- Manifolds
- Natural clustering
- Temporal and spatial coherence
- Sparsity
- Simplicity of Factor Dependencies

将来の汎用人工知能技術の
核心部分ではないか！？

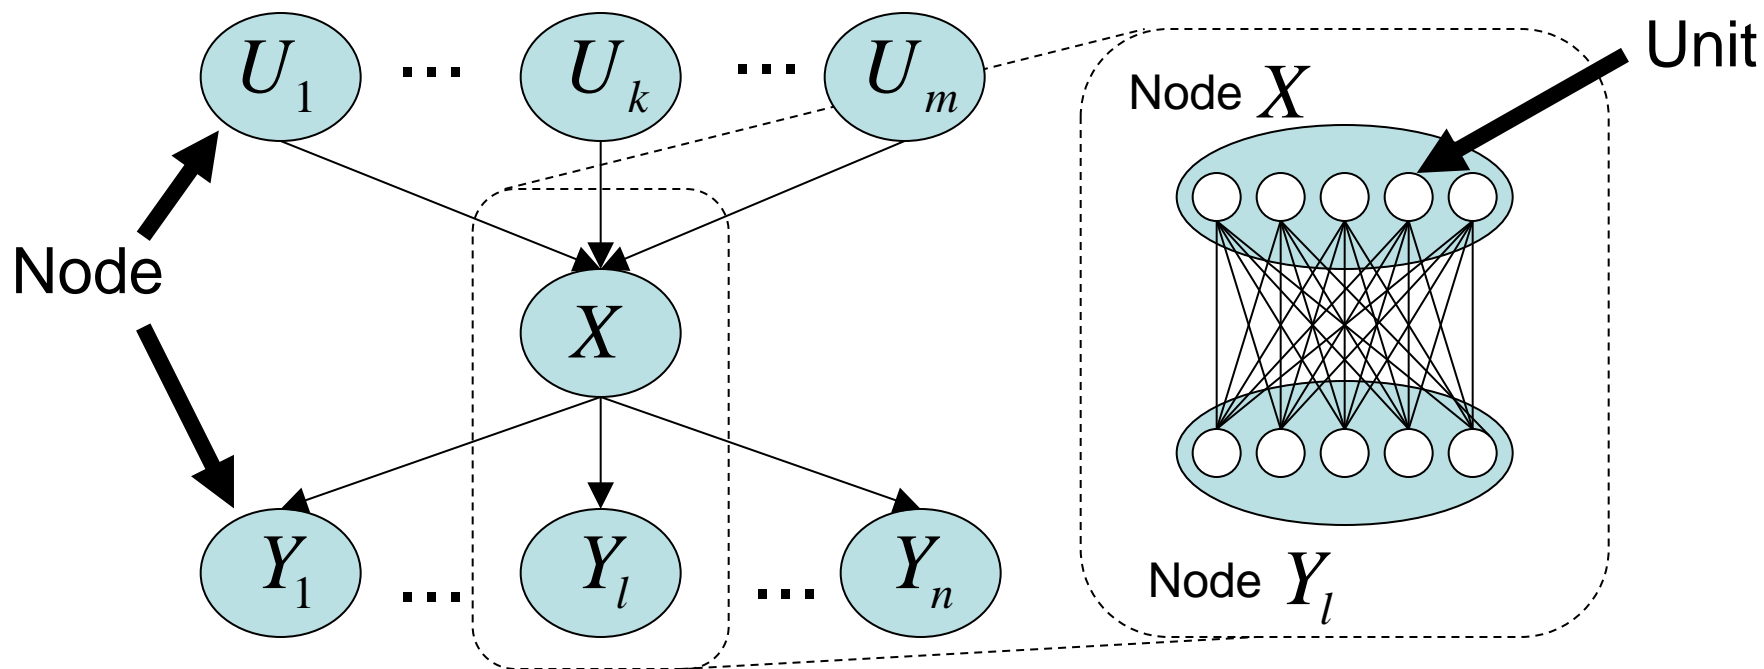
性能の良い「大脳皮質モデル」の構築に向けて解明すべきこと

- **汎用事前知識**: すべての大脳皮質領野に共通の事前知識
 - Bengio の generic priors をもっと具体化・追加していくべき。
- **領域事前知識**: 個別の領野ごとの事前知識
 - 他の領野や感覚器との間の接続関係。
 - 領野ごとのハイパパラメタ。
 - 例: 滑らかさの度合い、時間的変化のスピードなど。

これらを明らかにしていくには、
神経科学的知見と、学習対象の性質に関する工学的考察の両方が大事。

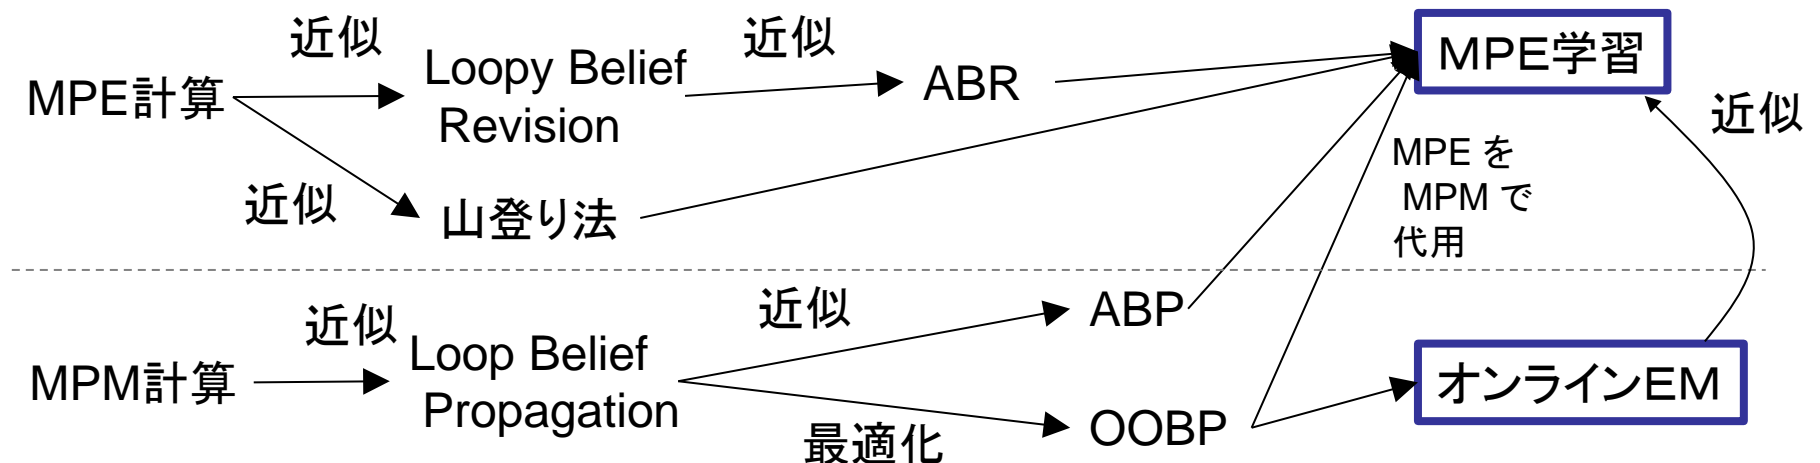
BESOM, 自己組織化マップ, ベイジアンネットワーク, 大脳皮質の構成要素の間の対応

BESOM	自己組織化マップ	ベイジアンネットワーク	大脳皮質
ノード	競合層	ノード (確率変数)	マクロコラム
ユニット	入力ベクトルの要素, 競合層のユニット	確率変数を取りうる値	ミニコラム
親ノード	入力層から見た競合層	親ノード (原因)	上位領野
子ノード	競合層から見た入力層	子ノード (結果)	下位領野
ユニットの出力	入力との類似度	事後確率	コラムの発火
結合の重み	参照ベクトルの要素	条件付確率	シナプスの重み

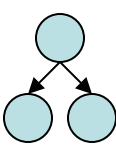
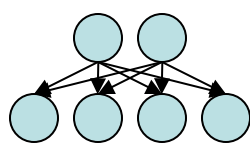
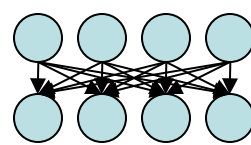
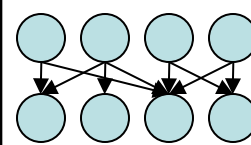
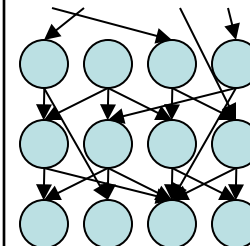
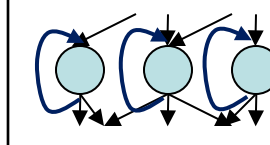


BESOM の学習に用いてきた 認識アルゴリズム

アルゴリズム	計算量	計算するもの	精度
Loopy Belief Revision	大	MPE	高い
Loopy Belief Propagation	大	周辺事後確率	高い
ABP (近似BP) [Ichisugi 2007]	小	周辺事後確率	低い
山登り法 [一杉 2009]	中	MPE	低い
ABR (近似BR)[Ichisugi 2011]	小	MPE	低い
OOBP (最適化BP) [一杉、高橋 2014]	小	周辺事後確率	高い



BESOM ネットのシミュレーション の現状

ネットワークの構造						
機能	近傍学習	非線形ICA	スパース符号化、混合分布	構造学習、特徴選択	多層化	短期記憶、SFA
実装	2007年	2009年	2009年	2011年	2012年	2013年 (部分的)
隠れノード数	1	2~3	3~10	3~10	10~100	10~100

計算量のオーダー(ノード数 n のとき1入力の認識・学習に必要な計算量)

- ・ 2007年 $O(2^n)$ 全数探索によるMPE計算
- ・ 2009年 $O(n^4)$ 山登り法
- ・ 2012年 ほぼ $O(n)$ 最適化BP、オンラインエッジ選択