

大脳皮質ベイジアンネットモデルの 実用化に向けて

第1回 全脳アーキテクチャシンポジウム

2016-05-18


産業技術総合研究所
人工知能研究センター
脳型人工知能研究チーム
一杉裕志



私の研究の長期的目標

- 脳全体のアーキテクチャを模倣して
「人間のような知能を持つ機械」を作る。


20～30年後？




脳のリバーエンジニアリング

産総研 脳型人工知能研究チームの 短期的目標

- あと4年で大脳皮質モデルの実用化の目途をつける。



大脳皮質の不思議さ



- 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。

大脳皮質の動作原理解明が最大の課題

大脳皮質と deep learning の類似点

- 領野の階層構造

- 視覚野 腹側経路 $V1 \rightarrow V2 \rightarrow V4 \rightarrow PIT \rightarrow CIT \rightarrow AIT$
- 視覚野 背側経路 $V1 \rightarrow V2 \rightarrow MT \cdot MIP \rightarrow MST \cdot LIP$
- 体性感覚野 $3野 \rightarrow 1野 \rightarrow 2野 \rightarrow 5野 \rightarrow SII \rightarrow 7b$
- 運動野 $M1 \rightarrow SMA \cdot PM$


- Deep learning との類似点

- 上の層ほど多くの特徴量（感覚入力）を統合。
- 上の層ほど複雑な情報を表現。
- 上の層ほど抽象度が高い情報を表現。

大脳皮質とベイジアンネットの類似点

- トップダウンとボトムアップの非対称の接続
- 局所的かつ非同期な情報のやり取りだけで動作
- 値が非負
- 情報が正規化される
- ヘブ則学習
- 文脈や事前知識に依存した認識
- ベイズに基づく動作

一杉裕志, 解説: 大脳皮質とベイジアンネット、
日本ロボット学会誌 Vol.29 No.5, pp.412--415, 2011.




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

Deep Learning の構造を持った 大規模ベイジアンネットの有望さ


- 脳の様々な高次機能が実現できる可能性がある。
- 事前知識を作り込みやすく、機械学習の手法としても有望。
- **実用化に向けて様々な困難があったが、かなり解決してきた。**

ベイジアンネットの将来性？




BESOM 実用化に向けた 研究開発の内容

制限付きベイジアンネット BESOM




- ・ 表現力の向上
- ・ 推論・学習の精度の向上
- ・ 大規模並列処理による処理速度向上

BESOM Ver.3 の 学習アルゴリズムの導出過程



脳のアルゴリズムの スケーラビリティ




著作者: artbejo

マウスの大脳皮質
ニューロン
約1600万個



約1000倍、
しかしどちらも
実時間動作




著作者: allvectors


ヒトの大脳皮質
ニューロン
約200億個

通常のベイジアンネットの問題点

推論・学習1ステップの
実行に必要な計算量




$$O(m)$$



$$O(2^m)$$

多くの推論・学習アルゴリズムにおいて
親ノードの数に対し
指数関数的な計算量が必要

解決策：定数個の親ノードを持つ等価なネットワークに変換 [Heckerman 1993]



親ノードの数 m 個

親ノードの数は高々2個で深さが $O(m)$


このような変換が可能な条件付確率表モデルであれば、
推論・学習の1ステップの実行が $O(2^m)$ から **$O(m)$ に高速化**

Noisy-OR モデル

noisy-OR モデル [Pearl 1988]

- すべて 2 値変数
- 親ノードのどれかが 1 のときに子ノードも 1
- 病気の原因と症状の関係など、多くの対象を
素直に表現可能、学習結果の解釈が容易

$$P(X = 0 | u_1, \dots, u_m) = \prod_{k=1}^m (1 - w_k)^{u_k}$$
$$P(X = 1 | u_1, \dots, u_m) = 1 - \prod_{k=1}^m (1 - w_k)^{u_k}$$



noisy-OR モデルは等価な 2 分木のネットワークに変換可能



$$P(T_0 = 0) = 1$$

$$P(T_{k+1} = 0 | T_k = 0, U_k = u_k) = (1 - w_k)^{u_k}$$

$$P(T_{k+1} = 0 | T_k = 1, U_k = u_k) = 0$$

$$X = T_m$$

$$P(X = 0 | u_0, \dots, u_{m-1}) = \prod_{k=0}^{m-1} (1 - w_k)^{u_k}$$



メッセージ

$$\pi(T_{k+1}) = \sum_{T_k, U_k} P(T_{k+1}|T_k, U_k) \pi_{T_{k+1}}(T_k) \pi_{T_{k+1}}(U_k)$$

$$\lambda_X(U_k) = \lambda_{T_{k+1}}(U_k) = \sum_{T_{k+1}} \lambda(T_{k+1}) \sum_{T_k} P(T_{k+1}|T_k, U_k) \pi_{T_{k+1}}(T_k)$$


$$\lambda(T_k) = \lambda_{T_{k+1}}(T_k) = \sum_{T_{k+1}} \lambda(T_{k+1}) \sum_{U_k} P(T_{k+1}|T_k, U_k) \pi_{T_{k+1}}(U_k)$$

$$\pi_{T_{k+1}}(T_k) = \pi(T_k)$$

$$\pi_{T_{k+1}}(U_k) = \pi_X(U_k)$$

$$\lambda(X) = \lambda(T_m)$$

$$\pi(X) = \pi(T_m)$$




學習

勾配法による学習則

- 隠れ変数のあるベイジアンネットは、局所的な演算だけで学習が実行可能

[Binder et al. 1997]

- 脳っぽい
- 並列処理が容易
- DNN の改善手法が適用可能



w を $P(x|pa(x))$ のパラメタとすると

$$\Delta w = \sum_{x, pa(x)} \frac{P_{\theta}(x, pa(x)|e)}{P_{\theta}(x|pa(x))} \frac{\partial P_{\theta}(x|pa(x))}{\partial w}$$


Noisy-OR の勾配法の学習則

$$\Delta w = \sum_{x, pa(x)} \frac{P_{\theta}(x, pa(x)|e)}{P_{\theta}(x|pa(x))} \frac{\partial P_{\theta}(x|pa(x))}{\partial w}$$

MPE の値の組み合わせに対し $P_{\theta}(x, pa(x)|e) = 1$ とする。

$$\Delta w_k = \begin{cases} 0 & (u_k = 0) \\ \frac{-\prod_{i \neq k} (1-w_i)^{u_i}}{\prod_i (1-w_i)^{u_i}} & (x = 0, u_k = 1) \\ \frac{\prod_{i \neq k} (1-w_i)^{u_i}}{1 - \prod_i (1-w_i)^{u_i}} & (x = 1, u_k = 1) \end{cases}$$

2層 noisy-OR ネットワークで 手書き数字「2」を教師なし学習



実験条件:

2層 noisy-OR ネットワーク

認識アルゴリズム: 山登り法

正則化: 勝率ペナルティと側抑制ペナルティ [一杉 2015]

20個の基底画像


平均3個の基底画像の和で
入力画像を表現するように学習

視覚野と言語野

視覚野モデルの開発内容

視覚野の様々な構造と機能を模倣したシステムを、制限付きベイジアンネット BESOM を用いて構築

たたみ込みNNは
腹側経路のみを模倣



視覚野の構造

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

言語野モデルの開発内容

制限付きベイジアンネット BESOM を用いて
文の意味を深く理解するシステムの実現を目指す

我々のアプローチ

言語に関する様々な分野の知見をヒントにする

神経科学の知見:

脳損傷による言語障害の症例
言語野周辺の解剖学的構造
fMRI による知見
大脳皮質の領野共通の知見

言語学の知見:

範疇文法、依存型意味論、格文法


自然言語処理の知見:

理論的に最適なアルゴリズム、有効なヒューリスティックス

言語野のモデル
の構築

「定性的ベイジアンネット」による プロトタイピング手法の開発

- ・ 確率値の0と非0のみを区別
- ・ 同時確率が非0になる解を**高速**に探索可能




```
% ネットワークの構造
possible(N1, N2, N3, N4, N5) :-
n5(N5,N3),n4(N4,N3),n3(N3,N1,N2),
n2(N2),n1(N1).
% 非0になる値の組み合わせのみ列挙
n1(true).
n1(false).
n2(true).
n2(false).
n3(true,true,true).
n3(false,false,true).
n3(false,true,false).
n3(false,false,false).
n4(true,true).
n4(false,false).
n5(true,true).
n5(false,false).
```

BESOM の完成を待たずに
人工視覚野、人工言語野の
モデル設計が可能に

定性的ベイジアンネットの
記述例


単語列と内部表現の間の 相互変換を行うベイジアンネット



脳内では受動態・能動態によらず、
動作主・被動作主の表現場所が
決まっている [Frankland et al. 2015]

「An architecture for encoding sentence meaning in
left mid-superior temporal cortex」
<http://www.pnas.org/content/112/37/11732.full?sid=b9968895-810f-4713-8887-ae0445dfa79b>

ベイジアンネット
で実現



プロトタイプを
定性的ベイジアンネットで構築

まとめ

- Deep Learning と同じ構造を持った大規模ベイジアンネットは有望
- 実用化に向けたいくつかの課題を解決
 - 理論的基盤の整理
 - スケーラビリティ
 - 並列実装
- 今後の課題
 - Loopy Belief Propagation の振動対策
 - 条件付確率表モデル拡張による表現力向上