

情報意味論 コネクショニズム connectionism

櫻井彰人
慶應義塾大学理工学部

1

本日の内容

- ニューロンとは
- ニューロンのネットワーク, i.e. ニューラルネットワーク
 - 長距離、階層的な構造
 - ローカルな構造
- モデル化
 - 単体
 - ネットワーク
- 使えるニューラルネットワーク

2

機械学習



希望: 次のような f を見つける for any true (x, y) $\min E[\text{loss}(y, f(x))]$
well-defined な問題ではない

loss は何が妥当か
一概には決められない
x の分布はどう考えるのか
あるともいえるし、ないともいえる
どんなデータにも適用する方法があるのか?
ない

予測値ではなく、「意味」を知りたいときは?
意味の分かる f を用いる
そのようなものはあるのか?
少しはある

3

ニューラルネットワークへの憧れ

- アイデアの宝庫(?)
- もの凄い学習能力、適応能力
 - 運動、言語、芸術、技術、社会、...
- ロバスト
 - 対損傷、対ノイズ、
- ひょっとして原理は簡単では?
 - 単純な素子(機能)の組み合わせ

4

背景

- 記号主義と非記号主義
- 記号主義
 - 1970年代~1980年代の一大潮流
 - 有効性と限界
- 非記号主義
 - 1980年代~1990年代のブーム
 - 夢と挫折
 - そして、復活

5

予めまとめ:ニューロンとは何か

- 神経細胞、実に多種多様
- 「発火」と呼ばれる動作をする
- 論理ゲートと考えると、1kHz の素子
- 頻度で情報をコード(と昔は考えた)
 - 今は、様々な方法でコードしていると考えられている
- 一つ一つの動作は、Hodgkin-Huxley方程式で、よく表現できる

6

ニューロンとは?

- “There is no such thing as a typical neuron”, Arbib, 1997




Fig. 1. The morphologies of these common types of neuron. The full length of the axons is not shown. The bifurcating axon of the granule cell extends for several millimeters in each direction. Note how the axon of the interneuron branches extensively.

7

多分典型的なニューロン





Fig. 1. Key features of a neuron. A drawing of a pyramidal cell showing the distribution of neurites (dendrites and axon).

8

ニューロンの活動 その1



9

ニューロンの活動 その2




図 27 ネズミの味覚の神経線維に現われるインパルス。数字は食塩のモル濃度 (C. Pfaffmann)

時実利彦「脳の話」より

10


Hodgkin-Huxley方程式

$$C_m \frac{dV}{dt} = -g_L(V - E_L) - g_{Na}m^3h(V - E_{Na}) - g_Kn^4(V - E_K) + I$$

$$\frac{dm}{dt} = \alpha_m(V)(1-m) - \beta_m(V)m$$

$$\frac{dh}{dt} = \alpha_h(V)(1-h) - \beta_h(V)h$$

$$\frac{dn}{dt} = \alpha_n(V)(1-n) - \beta_n(V)n$$



V: 膜電位、m, h(Na), n(K): チャンネルが開く確率


11

予めまとめ: ネットワーク

- シナプス結合を通じてネットワークを作る
 - Fan-in, fan-outが多い。1万とも言われる
- 「ネットワーク」らしい構造
 - 結構長距離結合: 視覚を例に。
- 「固まり」: 脳表面での構造
 - 視覚野におけるコラム構造
 - 視覚野における階層構造
 - 歴史的発見と修正。

12


ニューロンの結合



チャーチランド「認知哲学」から

13


視覚神経の結合



チャーチランド「認知哲学」から

14


網膜との結合



ゼキ「脳のビジョン」より

15


網膜との結合 (続)



ゼキ「脳のビジョン」より

16


補足: 人間の視覚野



ゼキ「脳のビジョン」より

17


大脳性盲



ゼキ「脳のビジョン」より

18

コラム構造の発見: 電極の挿入



(a)

ゼキ「脳のビジョン」より

19

V1野コラム構造の発見





図 22-2 V1野に電極を斜めに刺し進めて行って次々に捉えられる細胞の方位選択性の変化
(Hubel, D.H. & Wiesel T.N. (1977). *Proc. R. Soc. Lond. B* 198, 1-59. より転載).
(発見自体は、1959年。一次体性感覚野については、Mountcastleが1957年)

ゼキ「脳のビジョン」より

20


解剖学的手法 (眼優位)



ゼキ「脳のビジョン」より

21

眼優位コラムと 方位優位コラム




ゼキ「脳のビジョン」より

(a)

22


光活性物質(方位選択性)



「脳裏の小宇宙・
人体 II」より

23

V1~V3野の受容野の大きさ



ゼキ「脳のビジョン」より

24

階層構造概念の発展

- Hubel & Wiesel 以前:
 - (一次) 視覚野で中継し、連合野で高次処理
- 高次視覚野におけるコラムと受容野の変化
 - V1→V2→V3→... といった階層構造
- V1: 特徴抽出(特に傾き)
- V2: 対象受容野の拡大
- V3: 形の特徴
- V4: 色
- V5: 運動

補足: V1野コラム構造の訂正





図 19-2 V1野の機能に関する Hubel と Wiesel のキアム(a)と、後の Livingstone と Hubel による訂正 (Hubel, D.H. & Wiesel, T.N. (1977). Proc. R. Soc. Lond. B 208, 1-59 と Livingstone, M.S. & Hubel, D.H. (1984). J. Neurosci. 4, 309-356. 4-5転載)

補足: 階層構造への反論

- V1野における機能分化 (Zeki)
- V1野から既に属性ごとの並列処理


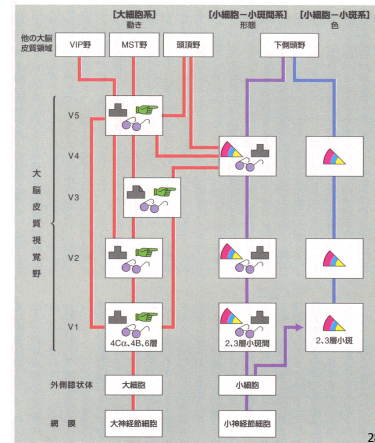



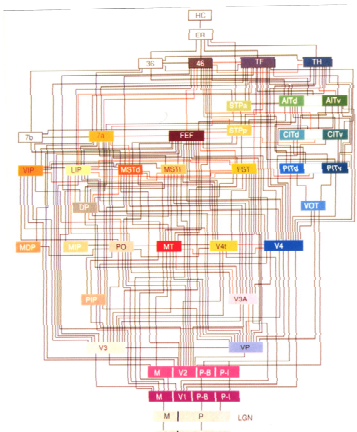
図 6 四種類の視覚経路と、V1野から前野内野の機能が専門化されている視覚領域までのそれぞれの解剖学的連絡結合の経路をまとめた図式 (本文 186 頁参照) (Zeki, S. The Visual Image in Mind and Brain. より許可を得て転載。著作権はすべて1992年に有限会社 Scientific American が取得)

補足: 視覚情報の流れ

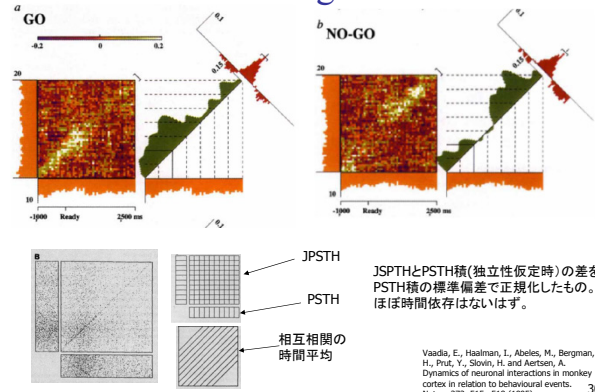


マウスの実験から想定されている視覚野の情報処理のスキーム (Kandel, "Principles of Neural Science" に基づく)

視覚野の結合関係



Temporal coding



JPSTHとPSTH積(独立性仮定時)の差をPSTH積の標準偏差で正規化したもの。ほぼ時間依存性はないはず。

Yasuda, E., Hashino, L., Abeles, M., Bergman, H., Paul, Y., Sloviter, H., and Aertsen, A. Dynamics of neuronal interactions in monkey cortex in relation to behavioural events. Nature 373, 515-518 (1995)

予めまとめ: モデル化

- 個別素子: McCulloch – Pitts モデル
 - 論理モデル、「電圧レベル」をモデル化
- ネットワーク: 階層
 - 次第に抽象的に
- しかし現実とは大きく異なる
- 使えるネットワークへ

31


ネットワークがモデル化できるか？

- できない。ニューロンモデルが複雑すぎる。
- 単純化する以外にない
 - 40年前の話ですから。
 - といっても、今でも事情はそうは変わらない

32

McCulloch and Pitts

- Warren S. McCulloch and Walter Pitts (1943) "A logical calculus of the ideas immanent in nervous activity", *Bulletin of Mathematical Biophysics*, 5: 115-133.




- ニューロンの非常に単純化した(しかし数学的な)モデル
- もしニューロンがこのようなであれば、任意の関数が計算できることを示した
-

33


ニューロンのモデル

- 個々のニューロンは、入力値をある関数に従って処理する
- 初期のモデルは階段関数を用いた。現在では、シグモイド関数を用いることが多い



34

視覚野のモデル(単純型細胞)




+: オン反応, -: オフ反応.
図 4.4 種々の単純型細胞の受容野 (Hubel & Wiesel¹⁾ を変更)

福島「神経回路と情報処理」より

35

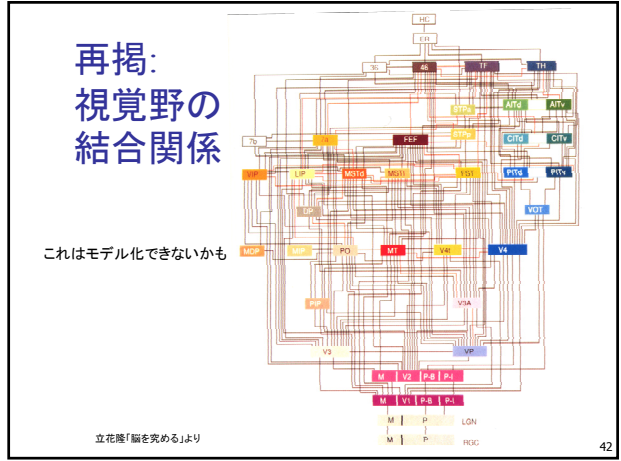
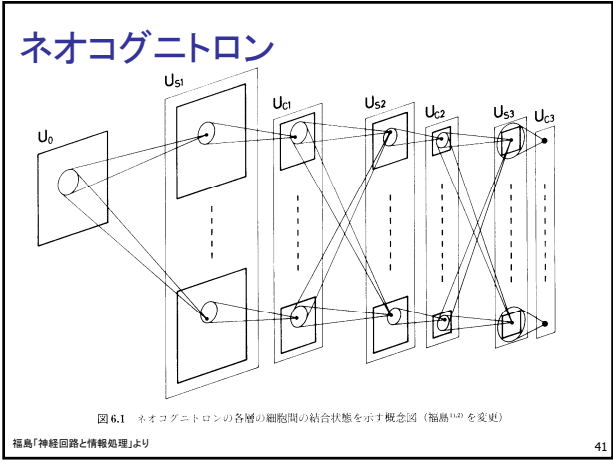

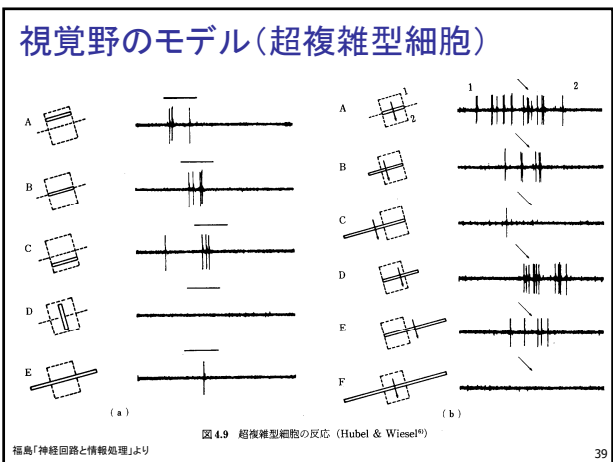
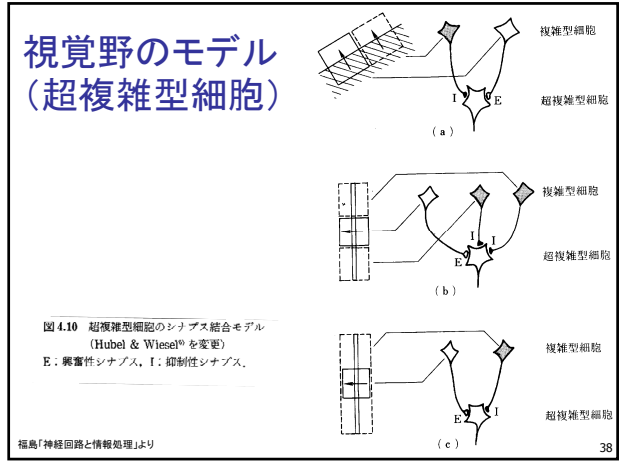
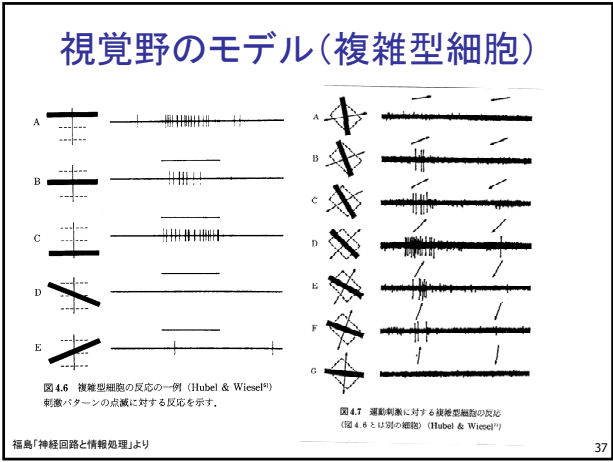
視覚野のモデル(複雑細胞)



+: オン反応, -: オフ反応
図 4.5 単純型細胞のシナプス結合モデル (Hubel & Wiesel¹⁾ を変更)

福島「神経回路と情報処理」より

36



まとめ: 使えるネットワーク

- 役立つ: 構造と学習
 - 単体: Hebb の学習則
 - 一層の構造: Perceptron 学習則
 - 多層の構造: 誤差逆伝播
 - 相互結合 (Hopfield/Boltzmann)
 - 相互結合 (recurrent)

43

ネットワークがモデル化できるか？

- モデル化するには、
- 単純化する以外にない、といった。しかし、
 - 単純な feedforward, 階層的構造ではない
 - 信号強度だけを考えればよい、というものでもない
- どうしているか
 - recurrent 結合、相互結合を設ける
 - feedforward ではなく、安定・時間発展・時系列という概念が入る
 - spike 型ニューロンによるモデル化
 - まだまだこれから

44

脳のモデル化ができるか？

- できない。
- と思う。
- 参考: コンピュータが(当分の間)脳にならない理由
 - active 素子の個数の違い
 - 結線数の違い
 - ソフトウェアの違い。
 - 真似するにせよしないにせよ、全くわかっていない。測定もできない
 - 大雑把には、測定できるようになってきている
 - cf 「ポスト・ヒューマン誕生—コンピュータが人類の知性を超えるとき」(原題 "The Singularity is Near") (レイ・カーツワイル, NHK出版, 2007年)

45

ニューロンにヒントを得た情報処理

- ニューラルネットは、ニューロンにヒントを得た情報処理モデルというべき
- 脳について知りえたことより、大幅に単純化されているのが、普通—とはいえ、イノベーションはしばしば脳研究から、例:
 - Spiking neural nets

46


ニューロンにヒントを得た情報処理

- ニューラルネットモデルは、超並列
 - 単純な処理装置の大量接続
- 記号処理とは異なった情報処理が行える
 - 異なる原始機能 (実行が容易) が使える
- **学習**ができる

47

再掲: McCulloch and Pitts

- Warren S. McCulloch and Walter Pitts (1943) "A logical calculus of the ideas immanent in nervous activity", *Bulletin of Mathematical Biophysics*, 5: 115-133.




- ニューロンの非常に単純化した(しかし数学的な)モデル
- もしニューロンがこのようであれば、任意の関数が計算できることを示した
- けれども、学習は...? あとで。

48

再掲: 処理系としてのニューロン


- 個々のニューロンは、入力値をある関数に従って処理する
- 初期のモデルは階段関数を用いた。現在では、シグモイド関数を用いることが多い



49

モデルニューロンのネットワーク

- ニューロンの単純化した数学的モデルが考えられた
- ...



50

Hebb 則

- Donald O. Hebb (1949) "The Organization of Behavior", New York: Wiley
- "What fires together, wires together"
- 生物学的には首肯できる
- 今でも用いられることがある (普通は使わない), 「ニューロン間の結合荷重は、その活動の相関に依存して変化する」という一般的な概念は、広く用いられている。

51

新たな構造: パーセプトロン Perceptron

- Rosenblatt, F. (1957). "The perceptron: A perceiving and recognizing automaton (project PARA)", Technical Report 85-460-1, Cornell Aeronautical Laboratory.
- Rosenblatt, F. (1962). "Principles of Neurodynamics.", Spartan Books, New York.




FIGURE 1. The one-layer perceptron analyzed by Minsky and Papert. (From *Perceptrons* by M. L. Minsky and S. Papert, 1969, Cambridge, MA: MIT Press. Copyright 1969 by MIT Press. Reprinted by permission.)

52

パーセプトロン

- 何ができるか?
 - 文字(アルファベット)認識
 - いくつかのパターン認識課題(形の認識等.)
 - しかも、素晴らしい学習則があった
- パーセプトロン学習規則は、それが解くことができる全ての課題について、解を発見することができる、と証明できる

53

しかし

- できないものがある
 - パリティ
 - 結合性
 - XOR 問題
 - 線形分離可能でない問題
- Marvin L. Minsky and Seymour Papert (1969), "Perceptrons", Cambridge, MA: MIT Press
- ネットワークにすればよいのでは?
- 正しい!
- McCulloch & Pitts ニューロンのネットワークは Turing 機械と等価;
 - でも 'それで?' というのは、
 - 学習させる方法を知らない
 - 予想: 任意のネットワークを学習させるアルゴリズムは、単に、存在しない

54


PDP 現る

- “Perceptrons” のせいで、この分野の研究が20年遅滞したという...
- 転機: D.E. Rumelhart, J.L. McClelland, eds., “Parallel Distributed Processing: Explorations in the Microstructure of Cognition”, MIT Press, 1986.
 - 論文の集成、数学的なものから哲学的なものまで
 - うまくいった実験結果をたくさん示している一方:
 - 誤差逆伝播学習アルゴリズム back propagation learning algorithm: 結局のところ多くのニューラルネットワークの学習を可能とした。
 - [実は、類似の技法は、この間、発見されていた (Amari 1967; Werbos, 1974, “dynamic feedback”; Parker, 1982, “learning logic”) ので、再発見という言葉が適している。しかし、この分野を再出発させたことは大きな成果である。]

55

Back Propagation


- 適用範囲: multi-layer ‘feed-forward’ (only) networks:



- 結合荷重は、誤差を逆伝播したものに比例して修正される...

56

何ができるか?



(Gorman & Sejnowski, NC 1(1), 75-89 (1988))

57

どうやって?

- 誤差関数の最急降下 (濃い霧の中の山くんだり...)
- 多層神経回路網のとき、この最急降下法がきれいに書けたことが良かった




Figure 10.6: Learning by gradient descent in weight/error space. (Axes are shown for only two of the 105 synaptic weights.)

58

NETTalk

- NETTalk: 興味深い課題:
 - 多くの利用可能な規則
 - 例外もおおい




Table 1 Symbols for phonemes used in NETTalk.

Symbol	Phoneme	Symbol	Phoneme
/a/	lather	/C/	chin
/b/	bat	/D/	dhis
/d/	daughter	/E/	bet
/d/	debt	/G/	veg
/e/	hake	/I/	bat
/f/	fin	/K/	sexual
/g/	guess	/L/	boots
/h/	acad	/M/	absum
/j/	Pete	/N/	fusion
/k/	Ken	/O/	boy
/l/	let	/Q/	quest
/m/	met	/R/	herd
/n/	net	/S/	slim
/o/	boat	/T/	thin
/p/	pet	/U/	book
/r/	real	/W/	boat
/s/	at	/X/	excess
/t/	test	/Y/	cute
/v/	late	/Z/	leisure
/w/	rest	/@/	bat
/x/	axet	/I/	Nazi
/y/	about	/B/	examine
/z/	yet	/P/	one
/A/	too	/J/	logic
/M/	late	/V/	bat

59

脱線: NETTalkと人との類似?

- NETTalk の学習過程で興味深い現象が観測された:
 - まず、子供のように、舌足らずでしゃべる
 - 広い規則を学習する、一般化しすぎだが
 - 最後に、例外も学習するようになる
- 訓練データに対しては、98% の正解率
- 新規データに対しても、86% の正解率 (cf. DECTalk なら 95% の正解率; 10年 vs. 一夏だが!)

60

NETTalk

- NETTalk が神経生理学的に妥当であるとは、誰も言わない。
- けれども、もし脳に少しでも似ているなら、(ヒントを求めて)NETTalkがどうやって学習したかを少しでも知りたいのが人情であろう
- 実際、様々な統計的手法が開発され、ニューラルネットの荷重と活動度により形成される「表現」が調べられた
- NETTalk については、その手法の一つがクラスタ分析である...

61

NETTalk: 活動のクラスタ分析




Figure 7.6 Hierarchical clustering of hidden units for letter-to-sound correspondences. The vectors of average hidden unit activity for each correspondence ("l-p" for letter l and phoneme p) were successively merging from right to left in the binary tree. The scale at the top indicates the Euclidean distance between the clusters. (From Sejnowski and Rosenberg 1987.)


62

NETTalk が学習したものは？

- NETTalk は、このクラスタ構造を直接教わることはなかった、データから自分で学習したのである
- 学習タスクを再実行するたびに(開始時の初期荷重はランダムに定める)まったく異なる荷重と活動度ベクトルが得られる、しかしクラスタ構造はほぼ同一になる
- 注: ニューラルネットワークが学習するときには、データは規則なり事実なりの形で記憶されることはない。分散した、記号化されていない表現 *sub-symbolic representations* を用いている

63

英語動詞の過去形の学習




- 英語の規則動詞、不規則動詞の学習を行わせた
 - 入力: 動詞原形、出力: 動詞の過去形
- 音韻的知見に基づく
- 未学習動詞に対しても正しい出力を出す。

Rumelhart et al 『Parallel Distributed Processing』

64

脱線: 学習中の正解率の変化




(注)「人間の過一般化とその解消の過程に類似している」との主張は、Chomsky派から極めて強い反論を受けた

Rumelhart et al 『Parallel Distributed Processing』

65

相互結合 (Hopfield)

- 対称, 自己結合なし
- 活動度非同期更新
- 重みの学習なし
- 平衡状態を求める
 - 各素子の活性値(0,1)を全エネルギー減少方向に変化させる
 - あるエネルギー関数の最小値に対応




66

相互結合 (Boltzmann machine)

- (基本構造は) Hopfield と同じ
- ただし、活性値(0,1)の更新は確率的
 - 全エネルギー減少方向へ。増加する確率 >0
 - このままでは、永遠に振動し続けるので、
 - 温度パラメータ T を持たせ、
 - T を徐々に変化させることにより、大域的最小値へ収束させる (simulated annealing by Kirkpatrick)
- 学習も考えることができる

67

文脈のモデル



Rumelhart et al. [Parallel Distributed Processing]

68

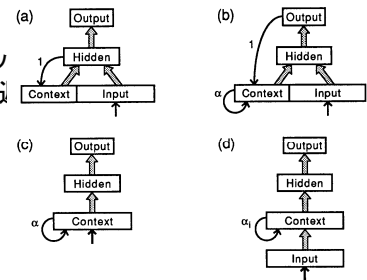
組み合わせ最適化に関する注意

- Hopfield ネットワーク等でとける
- しかし、専門のアルゴリズムより遅い
- 本来は、ニューラルネットワークの苦手の計算である。
 - 問題固有の「テクニック」を計算に組み込みたい
- 但し、小さい問題なら「とにかく解ける」という特質はある

69

相互結合 (recurrent)

- 階層型 + フィードバック (離散時間)




70

相互結合型 (recurrent)

- 基本的な機能: 状態機械 (オートマトン)
 - 1 time unit 毎、入力値 (feedback 値も含め) に基づき、次の活性値を決める
 - 時系列の分類、予測、変換等ができる
 - 不定長入力 (例: 文字列) 上の関数 (分類等) (feedforward では不定長入力は扱えない)
 - 有限状態とは限らない

71

文法の学習 (Elman)





$S \rightarrow NP VP \dots$
 $NP \rightarrow PropN \mid N \mid N RC$
 $VP \rightarrow V (NP)$
 $RC \rightarrow who NP VP \mid who VP (NP)$
 $N \rightarrow boy \mid girl \mid cat \mid dog \mid boys \mid girls \mid cats \mid dogs$
 $PropN \rightarrow John \mid Mary$
 $V \rightarrow chase \mid feed \mid see \mid hear \mid walk \mid live \mid chases \mid feeds \mid sees \mid hears \mid walks \mid lives$
 Additional restrictions:
 • number agreement between N & V within clause, and (where appropriate) between head N & subordinate V
 • verb arguments:
 $chase, feed \rightarrow$ require a direct object
 $see, hear \rightarrow$ optionally allow a direct object
 $walk, live \rightarrow$ preclude a direct object

•ランダムに10,000文生成し学習させる

J.L. Elman [Distributed Representations, Simple Recurrent Networks, and Grammatical Structure]

72



Deep Learning

75

DLN: 歴史における位置づけ

	第一次	第二次	第三次?
年代	1950後半～1960年代	1986～1990年代	2012～
キーワード	perceptron	back-propagation	deep learning
何ができるようになったか	閾値素子1個の学習	シグモイド素子の隠れ層1層NNの学習	シグモイド素子の隠れ層多層NNの学習
\$1,000, 1秒当りの計算回数	1～10	$10^5 \sim 10^6$	$10^9 \sim$
	IBM709～7090 (真空管～TR)	intel 486	core i7

76

タイトル(?)総なめ

Audio		TIMIT Speaker Identification	
Method	Accuracy	Method	Accuracy
Prior art (Clarkson et al., 1999)	79.6%	Prior art (Reynolds, 1995)	99.7%
Stanford Feature learning	80.3%	Stanford Feature learning	100.0%

Images		NORB Object classification	
Method	Accuracy	Method	Accuracy
Prior art (Krizhevsky, 2010)	78.9%	Prior art (Ranzato et al., 2009)	94.4%
Stanford Feature learning	81.5%	Stanford Feature learning	97.3%

Video		YouTube	
Method	Accuracy	Method	Accuracy
Prior art (Laptev et al., 2004)	48%	Prior art (Lu et al., 2009)	71.2%
Stanford Feature learning	53%	Stanford Feature learning	75.8%

KTH		UCF	
Method	Accuracy	Method	Accuracy
Prior art (Wang et al., 2010)	92.1%	Prior art (Wang et al., 2010)	85.6%
Stanford Feature learning	93.9%	Stanford Feature learning	86.5%

Multimodal (audio/video)		Other unsupervised feature learning records:	
Method	Accuracy	Task	Accuracy
Prior art (Zhao et al., 2008)	58.9%	Pedestrian detection (Yann LeCun)	
Stanford Feature learning	65.8%	Different phone recognition task (Geoff Hinton)	
		PASCAL VOC object classification (Kai Yu)	

Andrew Ng 77

DLNの大枠

- 特徴量を学習する
 - Hand-craftはしない
- 抽象度が低い特徴から抽象度の高い特徴までを階層的に学習する
 - 抽象度の低い特徴は、類似タスクで利用可能
- 主な手法
 - Deep belief networks (Hinton)
 - Deep autoencoder (Bengio)
 - Deep neural networks etc.

78



まとめ

- ニューロンとは
- ニューロンのネットワーク, i.e. ニューラルネットワーク
- モデル化
 - 単体
 - ネットワーク
- 使えるニューラルネットワーク
 - 単体
 - 一層
 - 多層
 - 相互結合
 - Deep learning network

79