

情報意味論 (多層)ニューラルネットワーク

櫻井彰人
慶應義塾大学理工学部

1

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
 - 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DNN、補足: 中間層表現
 - ESN

2

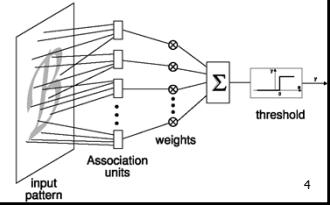
目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
 - 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DNN、補足: 中間層表現
 - ESN

3

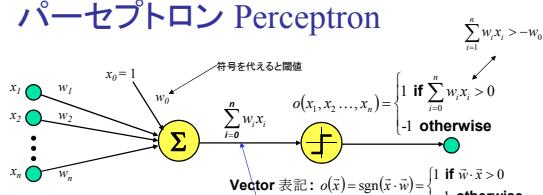
多義語: パーセプトロン

- パーセプトロン: 同じ言葉で別のものを指している
 - 線型閾値素子: 次のスライド
 - 元祖パーセプトロン: 下記。これが本當!
 - シグモイド素子: 今回の後半
 - シグモイド素子のネットワーク: 多層パーセプトロンと呼ばれる: 今回の後半
 - 線型閾値素子のネットワーク: 多層パーセプトロン。稀
- 本講義では、習慣に従い「間違った」用法に従う
- 元祖パーセプトロン
 - Rosenblatt 1962
 - Minsky and Papert 1969



4

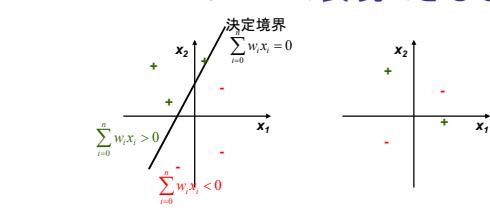
パーセプトロン Perceptron



- パーセプトロン Perceptron: 単一ニューロンのモデル
 - 別名 線型閾値素子 Linear Threshold Unit (LTU) or Linear Threshold Gate (LTG)
 - 素子への純入力 net input: 線型閾値 $net = \sum_{i=0}^n w_i x_i$
 - 素子の出力: 純入力に閾値閾数 threshold function を施したもの (閾値 threshold 0 = -w0)
 - 純入力に施して出力を得る閾数を 活性化閾数 activation function と呼ぶ
- パーセプトロンネットワーク Perceptron Networks
 - パーセプトロン同士が 荷重つき結合 weighted links w_i によって繋がっている
 - Multi-Layer Perceptron (MLP): 稀

5

パーセプトロンで表現できるもの



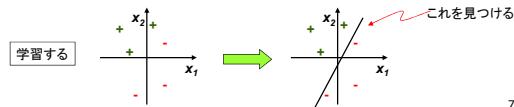
- パーセプトロン: 重要な関数がいくつも簡単に表現できる
 - 論理閾値 (McCulloch and Pitts, 1943) の多くのもの
 - e.g., 簡単な荷重で AND(x1, x2), OR(x1, x2), NOT(x)
- 表現できない関数もある
 - 線形分離不可能でないもの - 同語反復ですが

6

パーセプトロンで何をするか？

他の学習器と同じです

- 学習する
 - 学習データを $\langle \mathbf{x}_i, t_i \rangle$ とする ($1 \leq i \leq n$ 個数)
 - \mathbf{x}_i は(高次元)ユークリッド空間の点
 - t_i は +1 or -1
 - パラメータを調節して、 \mathbf{x}_i が入力されたとき t_i を出力するようにする
- 使用する(予測する)
 - \mathbf{x}_i と同じ次元の \mathbf{x} に対してそのあるべき出力 t を出力する



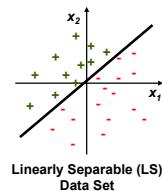
7

パーセプトロン学習アルゴリズム

- 単純な勾配降下 gradient descent アルゴリズムである
 - このアイデアは、適当な表現を用いれば、概念学習にも記号学習にも適用可能
- アルゴリズム Train-Perceptron ($D \equiv \{\langle \mathbf{x}, t(\mathbf{x}) \rangle\}$)
 - 荷重 w_i をランダム値に初期化する // パーセプトロン時は0に初期化してもよい
 - WHILE 正しい出力をしない事例がある DO
 - FOR それぞれの事例 $x \in D$
 - 現在の出力 $o = o(x)$ を計算
 - FOR $i = 1$ to n
 - $w_i \leftarrow w_i + r(t - o)x_i$ // r はある正数
- パーセプトロン学習可能
 - $h \in H$ のときのみ学習可能 - i.e., 線型分離可能 linearly separable (LS) functions
 - r が十分小さいことを条件とする説明もあるがそれは誤り
 - Minsky and Papert (1969) Perceptrons : 元祖パーセプトロンの表現・学習の限界を示した
 - 注: 素子一個では parity (n-変数 XOR: $x_1 \oplus x_2 \oplus \dots \oplus x_n$) 関数が表現できない、というのは既知
 - e.g., 画像の symmetry, connectedness は(元祖パーセプトロンで) 表現できない
 - "Perceptrons" のせいで ANN 研究が10年近く遅れたといわれもするが、それはなかろう。

8

線型分離可能



9

パーセプトロン学習の収束

- パーセプトロン学習の収束定理
 - 主張: もし訓練データと consistent な荷重集合があれば (i.e., データが線型分離可能なら), パーセプトロン学習アルゴリズムは収束する
 - 説明: 探索空間が外側界のある順序をなしている ("模の幅" が厳密に減少していく) - 参照 Minsky and Papert, 11.2-11.3
 - 注意 1: 収束までの平均時間は?
 - 注意 2: もし線型分離可能でなければどうなるのか?
- パーセプトロン循環定理
 - 主張: 訓練データが線型分離可能でなければパーセプトロン学習アルゴリズムにより得られる荷重ベクトルは、ある有界集合内に留まる。荷重が整数ベクトルなら、有限集合内に留まる。
 - 証明: もし十分に絶対値が大きい荷重ベクトルから始めると、絶対値は殆ど大きくなれないことが示せる。訓練事例の次元 n の数学的帰納法による - Minsky and Papert, 11.10

10

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DLN、補足: 中間層表現
 - ESN

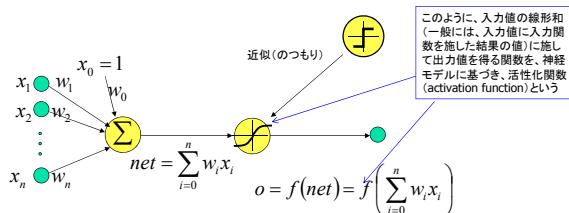
11

ネットワークの形

- 階層型(フィードフォワード型)
 - 多層ネットワーク
- 相互結合
 - フィードバック型(ディレイ付き、クロック付き)
 - 純相互結合
- モジュール & その結合

12

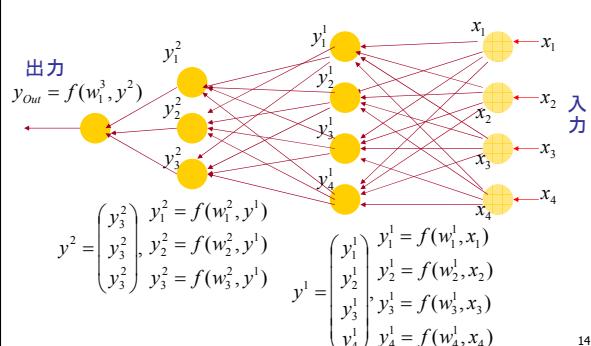
基本的素子: シグモイド素子



極めて頻繁に使われる活性化関数: $\sigma(x) \equiv \frac{1}{1+e^{-x}}$

13

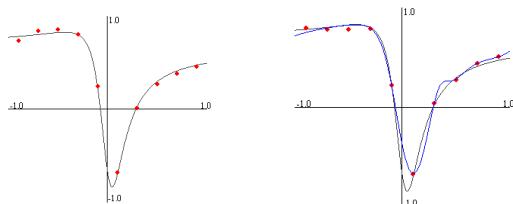
基本的な計算



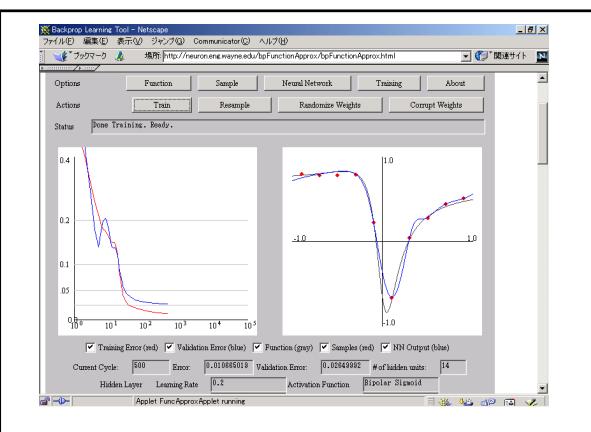
14

基本的な原理1: 関数近似・回帰

- 例: 1入力・1出力



15

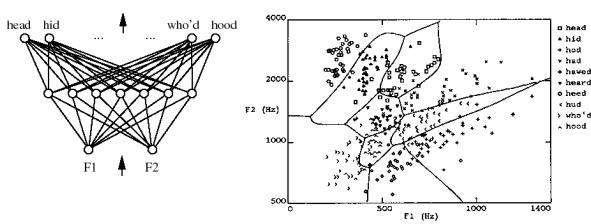


16

基本的な原理2: 分類

- 例: 音声認識

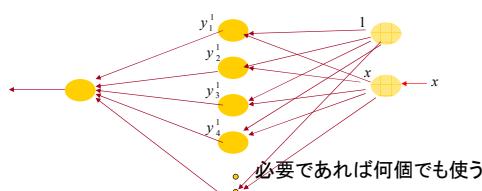
- 2入力・多出力
- 各入力値ごと、出力値の内、最大値を与えるクラスを分類結果とする



17

表現能力: 関数近似の場合

- 近似定理: ニューラルネットワークの中間素子数を必要なだけ用意できるなら、任意の滑らかな関数を任意の精度で近似することができる



K.Funahashi: "On the Approximate Realization of Continuous Mappings by Neural Networks", Neural Networks, 2, pp.183-192(1989).
G. Cybenko. Approximation by superpositions of a sigmoidal function. Mathematics of Control Signals Systems, 2:303-314, 1989

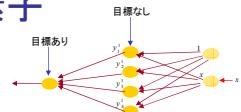
表現能力: 分類の場合

- 例: 2入力・1出力(図は閾値素子の場合)
 - 出力値を閾値以上か未満かで2クラスに分ける

構造	境界面の形	例1 対XOR問題	例2	例3
中間層なし	超平面			
中間層2素子	2超平面、それらを滑らかにしたもの			
中間層多素子	任意(但し、素子数に依存)			

学習方法: 閾値素子

- パーセプトロン学習法の拡張を考えた
 - 素子は、閾値素子で
- パーセプトロン学習のためには
 - 各素子で目標との差である「誤差」が必要
- しかし、多層パーセプトロンでは、出力素子以外には、「目標」がない
 - 一つの誤差(失敗)に多くの素子が関与している。
 - どの素子がどれだけ関与しているかを定め、責任(パラメータの修正量)を定める必要がある。
 - ご褒美で考えててもよい。ある利益を得た。貢献者に報酬を配りたい。当然貢献度合いに応じて配りたい。では、貢献度合いをどう定めればよいか?
 - こうした問題は、学習課題では頻繁に発生する。
 - 一般に、credit assignment problemといわれる
- つまり、パーセプトロン学習法は適用できない。
- さて、...



20

学習=誤差の最小化 -- シグモイド関数へ

- 基本的な考え方
 - 出力素子における、 $(\text{実出力} - \text{目標出力})^2$ を最小化しよう
 - この値、実際には、この値の全データ、全出力素子に関する総和、を $E(w)$ と書こう
 - パラメータは、素子間の結合荷重 w
 - $E(w)$ を w で微分(偏微分です)して0と置こう
 - 得られる w に関する方程式を解けばよい
 - パーセプトロンでは、微分できない
- では、微分できるようにしよう
 - 閾値関数をシグモイド関数に
- でも、解けない！複雑な非線形方程式だから
 - 数値計算にしよう。それでも、解けない。
 - 反復解法を考えよう



21

補足: 実は1980年代まで待ったなぜか？

- PDP (Parallel Distributed Computing) という書籍の出版を機に有名になった。しかし、
- 二乗誤差を求め、パラメータで微分し、0と置くのは、もっと前から常識であった。
 - 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、再発見だとも見える。貢献は「実際にうまくいく」ということを示したこと
- では、なぜ、こんなに遅くなったのか？ 考えられる理由：
 - 反復法で収束するとは思えなかった。
 - 反復法そのものが大変な計算と思われていた。
 - 考え方方が余りにも易しすぎて、極めて簡単な場合以外うまく行くとは思えなかつた
 - 甘利研でも修論のテーマぐらいであった。現在は当時の $10^4 \sim 10^5$ 倍ぐらい
 - 少し素子数が増えると、当時のコンピュータでは収束しなかつた
 - そんなことが脳内で行われているとは思わなかつた。

22

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DLN、補足: 中間層表現
 - ESN

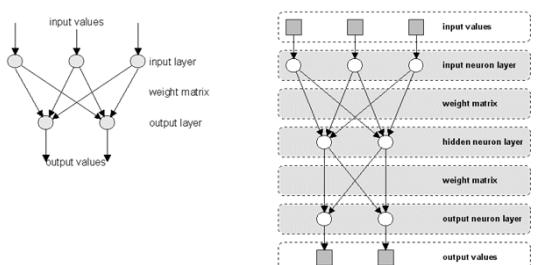
23

適用するネットワークの形状

- アイデア「学習=誤差最小化」は基本的なので、いろいろな場合に利用できる。
- 基本的には、
 - 階層型(feedforward)
 - 再帰型(recurrent)

24

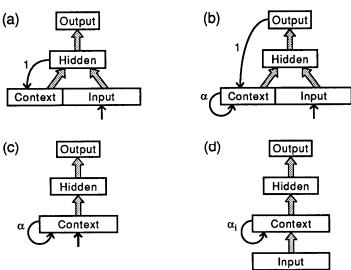
再掲：階層型（多層パーセプトロン）



25

再掲：相互結合 (recurrent)

- 階層型 + フィードバック (離散時間遅れ)



26

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DNN、補足: 中間層表現
 - ESN

27

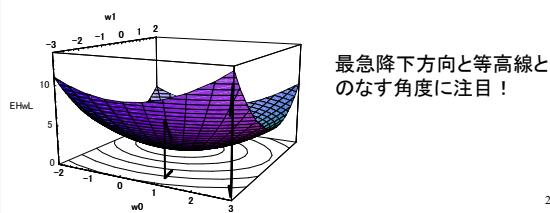
戻って：誤差最小化の方法

- 微分して0とおいた方程式を解けばよい！
本当か？
 - もっとも、まずは、微分できないことには話しにならん
 - つまり、パーセプトロンではだめ。
 - そこで、シグモイド関数にした。
- そうであっても
- 非線形連立方程式になり、到底、解けない
- 反復解法(少しづつ、解を改善していく方法)を考える。すなわち、 $E(W_1) > E(W_2) > E(W_3) > \dots$ となる W_1, W_2, W_3, \dots を求める方法を考える

28

反復最小化法

- 様々な方法が提案されている。
- 中でも最も単純なものが、最急降下法
 - 最大値を求めるなら、最急上昇法(あまり使わない)。



29

最急降下法の計算式

- 実際の計算はどうすればよいか？
- 微係数は、最急上昇方向であった！
- そこで、

$$\Delta W = \alpha \left(-\frac{\partial E}{\partial W} \right)$$

$$W \leftarrow W + \Delta W$$

とする。 α は学習係数(上手に決めないといけない定数)

30

学部生に戻って

$$E = (t - y)^2$$

$$\frac{\partial E}{\partial W} = 2(t - y) \underbrace{\frac{\partial(t - y)}{\partial W}}_{= -2(t - y)x}$$

< どいですが $\frac{d}{dx}[f(x)]^2 = 2f(x)\frac{d}{dx}f(x)$

活性化関数が恒等関数の場合、i.e. $y = \sum_{i=1}^n w_i x_i$

$$\begin{aligned} \frac{\partial(t - y)}{\partial W} &= -\frac{\partial y}{\partial W} \quad (t \text{ は目標値であり、 } W \text{ に依存しない}) \\ &= -\frac{\partial \left(\sum_{i=1}^n w_i x_i \right)}{\partial W} \\ &= -x \quad (x \text{ はベクトルです}) \end{aligned}$$

もう少し

$$W \leftarrow W + \alpha \left(-\frac{\partial E}{\partial W} \right) \quad \text{かつ} \quad \frac{\partial E}{\partial W} = -2(t - y)x$$

であるから、 2α を α と書き換えれば

$$W \leftarrow W + \Delta W \quad \text{かつ} \quad \Delta W = \alpha(t - y)x$$

この形の学習則を1個のニューロンに適用した規則は、デルタ則とも呼ばれる (Widrow-Hoff 則とも呼ばれる)

$$y = \sum_{i=1}^n w_i x_i \quad \text{を仮定している}$$

32

Perceptron 学習則との関係

- しかし、学習則だけみてみると、perceptron 学習則

$$W \leftarrow W + \Delta W \quad \text{かつ} \quad \Delta W = \begin{cases} x & \text{if } t \neq y \text{ and } t = 1 \\ -x & \text{if } t \neq y \text{ and } t = -1 \\ 0 & \text{if } t = y \end{cases}$$

は、下記において、 $t = \pm 1, y = \pm 1$ という状況で、 $\alpha = 1/2$ とおいたもの

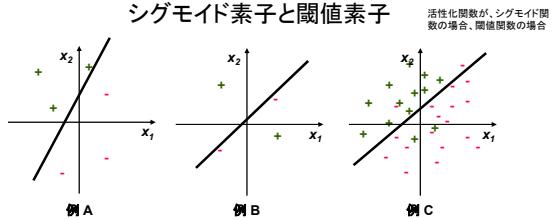
$$W \leftarrow W + \Delta W \quad \text{かつ} \quad \Delta W = \alpha(t - y)x$$

- しかし閾値関数は微分不能なため、perceptron 学習則の妥当性は、二乗誤差最小化では説明できない。

33

デルタ規則とperceptron学習則

シグモイド素子と閾値素子

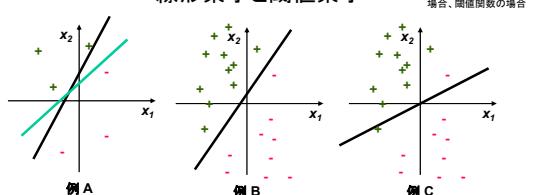


- 線型分離可能: 完全な分類ができる
 - 例 A: バーセptron学習アルゴリズムが収束
- 線型分離不能: 近似できるのみ
 - 例 B: 線型分離不能: デルタ規則は収束、しかし3個正解よりはよくならない
 - 例 C: 線型分離不能: デルタ規則でよい結果

34

デルタ規則とperceptron学習則

線形素子と閾値素子



- 線型分離可能: 同じ分類をする
 - 例 A: バーセptron学習則もデルタ規則(線形素子)も同じ分類をするただし、結果は異なるので、未知入力に対する動作は異なる可能性あり
- 線型分離不能: 異なる分類をする。線形素子の場合、全体のバランスをとる
 - 例 B: 線型分離可能: Perceptron学習則は正解通り分類
 - 例 C: 線型分離不能: デルタ規則は正解通りには分類しない。バランスはよい?

35

活性化関数が恒等関数以外のとき

$$\begin{aligned} \Delta W_s &\leftarrow \alpha(t - y)f'(y_{in})x_s \\ W &\leftarrow W + \Delta W_s \end{aligned}$$

ΔW_s サンプル s に対する荷重の更新量

α 学習率 (スカラー、多くの場合定数)

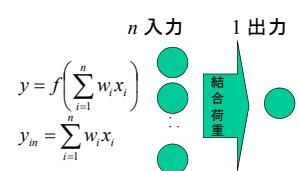
t 目標値

x_s サンプル s

$$y_m = \sum_{i=1}^n w_i x_i$$

f 活性化関数。微分可能

$$y = f(y_{in}) \quad \text{実際の出力値}$$



$$y_{in} = \sum_{i=1}^n w_i x_i$$

もう一度

$$E = (t - y)^2$$

$$\frac{\partial E}{\partial W} = 2(t - y) \underbrace{\frac{\partial(t - y)}{\partial W}}_{= -2(t - y)f'(y_{in})x}$$

$$y = f(y_{in}), y_{in} = \sum_{i=1}^n w_i x_i$$

$$\begin{aligned} \frac{\partial(t - y)}{\partial W} &= -\frac{\partial y}{\partial W} \\ &= -\frac{\partial f(y_{in})}{\partial W} \\ &= -\frac{\partial f(y_{in})}{\partial y_{in}} \frac{\partial y_{in}}{\partial W} \\ &= -f'(y_{in}) \frac{\partial \left(\sum_{i=1}^n w_i x_i \right)}{\partial W} \\ &= -f'(y_{in}) x \end{aligned}$$

(x はベクトルです)

前と全く同様に

$$W \leftarrow W + \alpha \left(-\frac{\partial E}{\partial W} \right) \quad \text{かつ} \quad \frac{\partial E}{\partial W} = -2(t - y)f'(y_{in})x$$

であるから、 2α を α と書き換えれば

$$W \leftarrow W + \Delta W \quad \text{かつ} \quad \Delta W = \alpha(t - y)f'(y_{in})x$$

38

ところで

- これまで、サンプルが一個与えられたときの、荷重更新を考えてきた。
- しかし、これは、おかしい。
- なぜなら、誤差というものは、与えられたサンプル全体に対する誤差を考えないと意味がない
- なぜなら、あるサンプル x_1 に関する誤差を減少させた結果、他のサンプル x_2 に対する誤差が増加してしまい、結果として、全体誤差は増加してしまう可能性があるからである
- であるから、

$$E = (t - y)^2 \quad \text{ではなく} \quad E = \sum_s (t_s - y_s)^2$$

そして、

$$W \leftarrow W + \Delta W \quad \text{かつ} \quad \Delta W = \alpha \sum_s (t_s - y_s) f'(y_{in,s}) x_s$$

であるべき（これを batch mode という（vs. online mode））

正しい議論か？

- 完全に正しい。そしてこの時、 α が定数でなく、学習ステップを繰り返す間に、適度な速度で $\alpha \rightarrow 0$ となるなら、
- $$W \leftarrow W + \Delta W \quad \text{かつ} \quad \Delta W = \alpha \sum_s (t_s - y_s) f'(y_{in,s}) x_s$$
- によって、 $E = \sum_s (t_s - y_s)^2$ は（局所）最小値となることが示される
- では、batch mode の方がいいのか？
 - 話はそう簡単ではない。
 - 実は、online mode の方が、一般に、より小さい E を得ることが経験上知られている。
 - なぜだろう？

40

出力素子が複数個のとき

$$\Delta W_{s,j} \leftarrow \alpha(t_j - y_j)f'(y_{in,j})x_s$$

$$W_j \leftarrow W_j + \Delta W_{s,j}$$

$\Delta W_{s,j}$ サンプル s に対する第 j 出力素子への荷重の更新量

α 学習率（スカラー、多くの場合定数）

t_j 第 j 出力素子の目標値

x_s サンプル s

$$y_{in,j} = \sum_{i=1}^n w_{i,j} x_i$$

f 活性化関数：微分可能

$$y_j = f(y_{in,j}) \quad \text{実際の出力値}$$

$$y_j = f\left(\sum_{i=1}^n w_{i,j} x_i\right)$$

$$y_{in,j} = \sum_{i=1}^n w_{i,j} x_i$$

前と全く同様に

$$W_j \leftarrow W_j + \alpha \left(-\frac{\partial E}{\partial W_j} \right) \quad \text{かつ} \quad \frac{\partial E}{\partial W_j} = -2(t_j - y_j)f'(y_{in,j})x$$

であるから、 2α を α と書き換えれば

$$W_j \leftarrow W_j + \Delta W_j \quad \text{かつ} \quad \Delta W_j = \alpha(t_j - y_j)f'(y_{in,j})x$$

42

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DLN、補足: 中間層表現
 - ESN

43

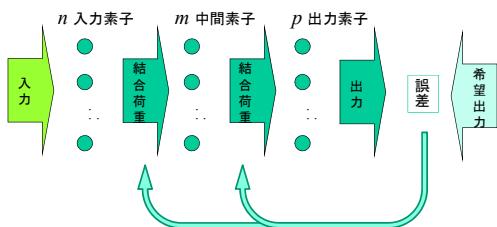
多層のネットワークでは?

- 各中間素子での荷重更新量をどうやって求めればよいか
- perceptron 学習規則やデルタ規則を見れば分かるが、荷重の更新量を求めるためには、誤差が必要である。そのためには、目標出力値が必要である。
- ところが、中間素子には、目標出力値がない(与えられていない!)
- 実出力値は、勿論、ある
- つまり、ネットワーク全体では(従って、出力素子では)誤差が定義できるが、個々の中間素子における誤差は定義できない、すなわち、全体誤差の中間素子への割り振り方が分からぬ。
- このように、ある系全体での利得や損失が分かったとき、その貢献・負担を各構成員にどのように分配すべきかという問題は、いろいろな場面で発生する。
- この問題は、credit assignment の問題といわれる。
- 中間層があるNNで、credit assignment 問題が発生したのである

文献に対する賞賛・評価、
credit titleのcreditと同じ

44

Credit Assignment 問題



- このように、ある系全体での利得や損失が分かったとき、その貢献・負担を各構成員にどのように分配すべきかという問題は、いろいろな場面で発生する。
- この問題は、credit assignment の問題といわれる。
- 中間層があるNNで、credit assignment 問題が発生したのである

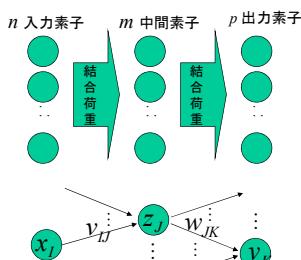
45

シグモイド素子を使えば

- しかし、シグモイド素子のように、微分可能な活性化関数を持つ場合には、別の考え方があり、それに従えば自動的に credit assignment の問題は解消する
- すなわち、デルタ規則のときと全く同様に、

$$E = \sum_s (t_s - y_s)^2$$
 とおき、例えば、最急降下法を適用すればよい

46

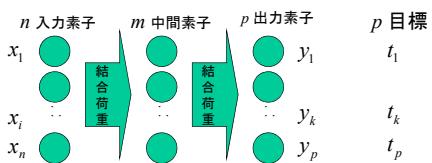


以前は、 $E = (t - y)^2$ ただし: $\begin{cases} t & \text{目標出力} \\ y & \text{実出力} \end{cases}$

今回は、p 出力を考える。ただし、サンプル数は1個としておく:

$$E = \sum_{k=1}^p [t_k - y_k]^2$$

47



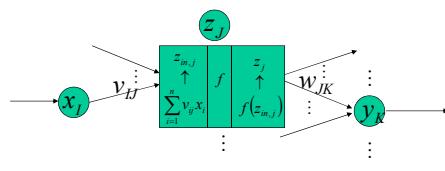
$$E = \sum_{k=1}^p [t_k - y_k]^2$$

48

前進: 出力値の計算

$$z_{in,j} = \sum_{i=1}^n v_{ij} x_i$$

$$z_j = f(z_{in,j})$$

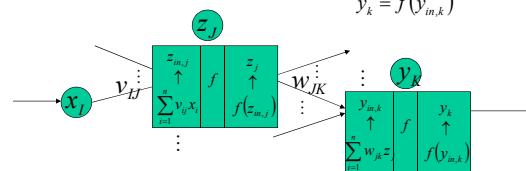


49

前進: 出力値の計算

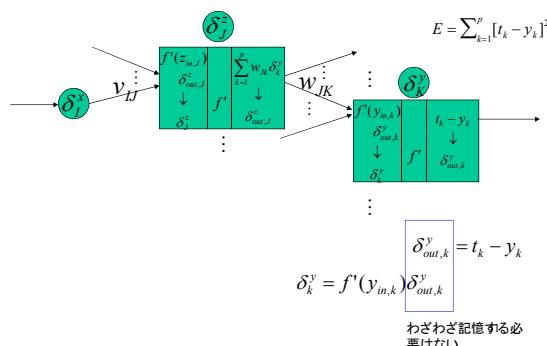
$$y_{in,k} = \sum_{j=1}^m w_{jk} z_j$$

$$y_k = f(y_{in,k})$$



⋮

後退: 誤差値の計算



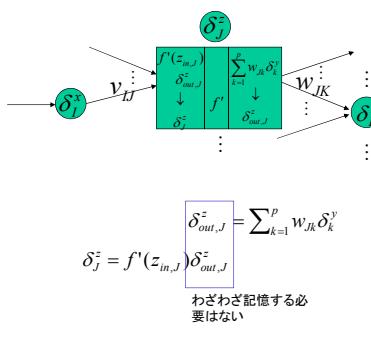
$$E = \sum_{k=1}^p [t_k - y_k]^2$$

$$\delta_k^y = t_k - y_k$$

$$\delta_k^y = f'(y_{in,k}) \delta_{out,k}^y$$

わざわざ記憶する必要はない

後退: 誤差値の計算



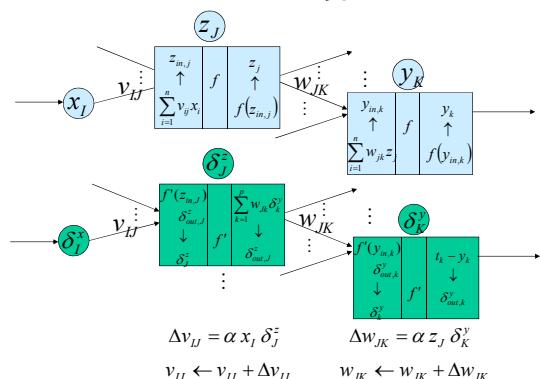
$$\delta_j^z = \sum_{k=1}^p w_{jk} \delta_k^y$$

$$\delta_j^z = f'(z_{in,J}) \delta_{out,J}^z$$

わざわざ記憶する必要はない

52

修正量の計算



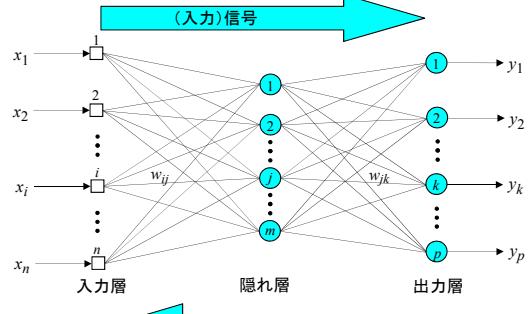
$$\Delta v_{IJ} = \alpha x_I \delta_j^z$$

$$v_{IJ} \leftarrow v_{IJ} + \Delta v_{IJ}$$

$$\Delta w_{JK} = \alpha z_j \delta_K^y$$

$$w_{JK} \leftarrow w_{JK} + \Delta w_{JK}$$

3層(中間層1層)の神経回路網



誤差逆伝播法(error back-propagation or BP)

54

プログラム例

```
//入力層
for(int i=0; i<N_INPUT; i++){
    input[i] = (double)in[i];
}

//隠れ層の計算
for(int i=0; i<N_HIDDEN; i++){
    hidden[i] = 0.0;
    for(int j=0; j<N_INPUT; j++){
        hidden[i] += w1[j][i] * input[j];
    }
    hidden[i] = sigmoid(hidden[i]);
}

//出力層の計算
for(int i=0; i<N_OUTPUT; i++){
    output[i] = 0.0;
    for(int j=0; j<N_HIDDEN; j++){
        output[i] += w2[j][i] * (hidden[j]);
    }
    output[i] = sigmoid(output[i]);
}

//sigmoid関数
public double sigmoid(double x){
    double a = 1.0 / (1.0 + Math.exp(-x));
    return a;
}
```

http://d.hatena.ne.jp/poor_code/20090711/1247334880

まとめ1: 教師付き学習

結合荷重の求め方

- 学習データを $\{(x_t, y_t) | 1 \leq t \leq N\}$ とする
- またネットワークの入出力関係を $y = F(W, x)$
- 誤差関数を設定する。通常は、

$$E(W) = \frac{1}{N} \sum_{t=1}^N (F(W, x_t) - y_t)^2$$

- この E を最小化する W を求めればよい

56

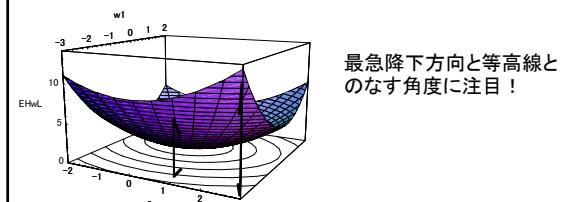
まとめ2: 誤差最小化の方法

- 微分して0とおいた方程式を解けばよい！
それはそうだが、本当か？
 - まずは、微分できないことには話しにならん
 - パーセプトロンではだめ。
- 非線形連立方程式になり、到底、解けない
- 反復解法(少しづつ、解を改善していく方法)を考える。すなわち、 $E(W_1) > E(W_2) > E(W_3) > \dots$ となる W_1, W_2, W_3, \dots を求める方法を考える

57

まとめ3: 反復最小化法

- 様々な方法が提案されている。
- 中でも最も単純なものが、最急降下法
 - 最大値を求めるなら、最急上昇法(あまり使わない)。



58

まとめ4: 反復最小化方法の計算式

- 実際の計算はどうすればよいか？
 - 微係数は、最急上昇方向であった！
 - そこで、 $\Delta w_i^j = -\eta \cdot \frac{\partial E}{\partial w_i^j}(W)$
- $$w_i^{j,new} = w_i^j + \Delta w_i^j$$
- とする。 η は学習係数(上手に決めないといけない定数)

59

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DLN、補足: 中間層表現
 - ESN

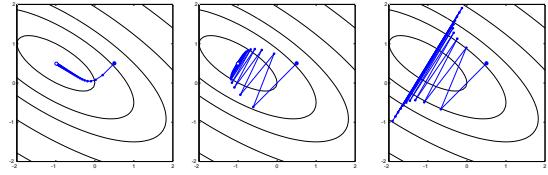
60

誤差逆伝播法の収束

- 大域的な最適解への収束は保証されない
 - 比較: バーセプトロンの収束 (最適な $h \in H$ に, 但し $h \in H$ なる条件下; i.e., 線型分離可能)
 - ある局所最適解 (まあ大域的最適解ではなかろう) へ近づいて行く
 - backprop (BP) に対する改善 (かもしれない)
 - 慣性項 (荷重更新規則を多少変更): 浅い局所最小解はスキップするかも
 - $\Delta W^{new} \leftarrow \Delta W + \alpha \Delta W^{new}$; 加速係数は1より小さい定数
 - 確率的最急降下 stochastic gradient descent: 局所解に捕まる確率が低下
 - 複数個のネットを異なる荷重値で初期化; うまく混合する
 - フィードフォワードネットワークの改善
 - ANNs のベイズ学習 Bayesian learning (e.g., simulated annealing)
- 収束過程
 - 0に近い初期値, i.e., 線型に近いネットワークから開始, 徐々に非線形ネットワークへ: 未解明
- プラトーと収束速度
 - プラトーの解消: 自然勾配法 natural gradient [Amari, 1998]

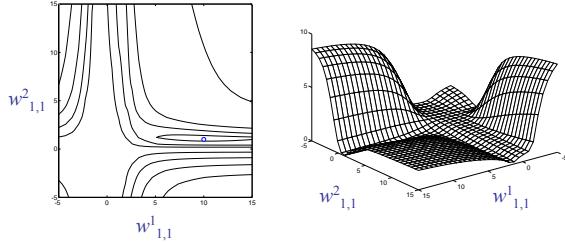
61

学習パラメータによる違い



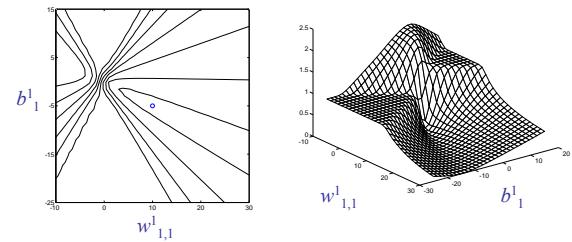
62

二乗誤差 vs. $w_{1,1}^1$ と $w_{1,1}^2$



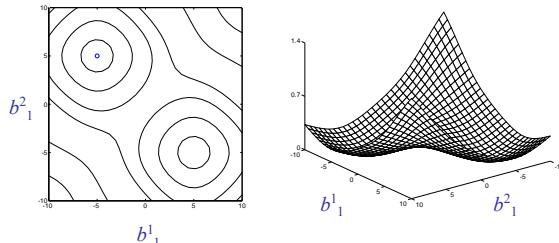
63

二乗誤差 vs. $w_{1,1}^1$ と b_1^1



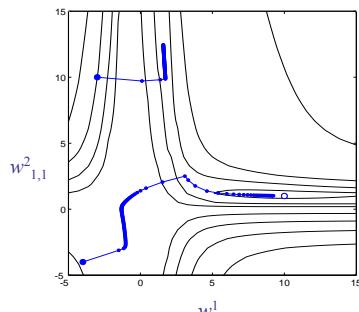
64

二乗誤差 vs. b_1^1 と b_2^1



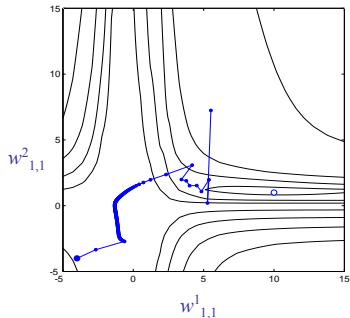
65

収束過程の例



66

学習係数が大きすぎる場合



67

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DNN、補足: 中間層表現
 - ESN

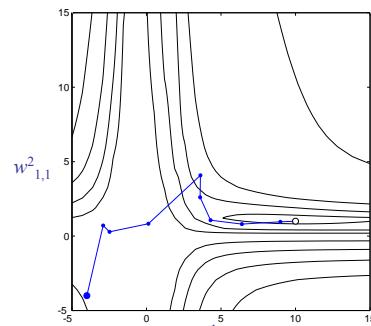
68

BP法で満足か？

- とんでもない！
 - "最適化法" でできることがわかつてしまえば、最急降下法よりよい（よさそうな）ものは、いくらでもある。
- 様々な方法が試みられた
 - それなりにうまくはいくのだが、目を見張るほどではない
 - 特に問題なのは計算時間
 - 高速な手法は、 $|W| \times |W|$ ($|W|$ は荷重の個数) の行列の逆行列の計算が必要とするから
 - 逆行列を、荷重の逐次更新とともに、逐次近似する方法が用いられる
 - それに見合うだけの、成功率と局所解回避率が得られない
 - Neural Networks は単純な形のようだが、結構性質が悪い。特に「特異点」があつて、収束を遅くしたり、行列が特異になつたりする
 - 私が調べ・試みた中で最良のものは、Levenberg-Marquardt 法

Timothy Masters, Advanced Algorithms for Neural Networks: A C++ Sourcebook, John Wiley & Sons (1995).

Levenberg-Marquardt 法



70

LMの説明のために: BP

最急降下法

$$\Delta \mathbf{w}^{(k)} = -\alpha \mathbf{g}^{(k)} \quad \mathbf{g} = \frac{\partial E}{\partial \mathbf{w}} \quad E = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{pm}^2$$

利点:

- 簡単
- (比較的) 安定

欠点:

- 学習能力が低い(失敗することが多い)
- 収束が遅い

71

LMの説明のために: ニュートン法

- ニュートン法: 非線形方程式の解の近似解法。極小点(停留点)の座標を求めるのに使用

$$\Delta \mathbf{w}^{(k)} = -(\mathbf{H}^{(k)})^{-1} \mathbf{g}^{(k)}$$

$$\mathbf{g} = \frac{\partial E}{\partial \mathbf{w}} \quad \mathbf{g}_i = \frac{\partial E}{\partial w_i}$$

$$\mathbf{H} = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1^2} & \frac{\partial^2 E}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_1 \partial w_N} \\ \frac{\partial^2 E}{\partial w_2 \partial w_1} & \frac{\partial^2 E}{\partial w_2^2} & \dots & \frac{\partial^2 E}{\partial w_2 \partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 E}{\partial w_N \partial w_1} & \frac{\partial^2 E}{\partial w_N \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_N^2} \end{bmatrix}$$

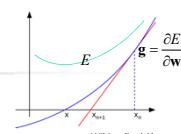
$$E = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{pm}^2$$

利点:

- 収束が早い

欠点:

- 安定性に乏しい
- (誤差関数の)2階微分を計算する必要がある



72

LMの説明のために: ガウス・ニュートン法

- ガウス・ニュートン法: ニュートン法における2階微分の計算を省略する。ヤコビアンを用いる。なお、誤差関数が2乗和であることを利用している。

$$\Delta \mathbf{w}^{(k)} = -\left(\mathbf{J}^{(k)T} \mathbf{J}^{(k)}\right)^{-1} \mathbf{J}^{(k)T} \mathbf{e}^{(k)}$$

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{pm}^2$$

$$\mathbf{g} = \mathbf{J}^T \mathbf{e}$$

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} + \text{2nd derivative}$$

$$\approx \mathbf{J}^T \mathbf{J}$$

d. ニュートン法
 $\Delta \mathbf{w}^{(k)} = -\alpha (\mathbf{H}^{(k)})^{-1} \mathbf{g}^{(k)}$

- 利点:**
 - 収束が高速
- 欠点:**
 - 不安定

$$\mathbf{J} = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \frac{\partial e_{1,1}}{\partial w_2} & \dots & \frac{\partial e_{1,1}}{\partial w_N} \\ \frac{\partial e_{1,2}}{\partial w_1} & \frac{\partial e_{1,2}}{\partial w_2} & \dots & \frac{\partial e_{1,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{1,M}}{\partial w_1} & \frac{\partial e_{1,M}}{\partial w_2} & \dots & \frac{\partial e_{1,M}}{\partial w_N} \\ \frac{\partial e_{p,1}}{\partial w_1} & \frac{\partial e_{p,1}}{\partial w_2} & \dots & \frac{\partial e_{p,1}}{\partial w_N} \\ \frac{\partial e_{p,2}}{\partial w_1} & \frac{\partial e_{p,2}}{\partial w_2} & \dots & \frac{\partial e_{p,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{p,M}}{\partial w_1} & \frac{\partial e_{p,M}}{\partial w_2} & \dots & \frac{\partial e_{p,M}}{\partial w_N} \end{bmatrix}, \quad \mathbf{e} = \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ \vdots \\ e_{1,M} \\ \vdots \\ e_{p,1} \\ e_{p,2} \\ \vdots \\ e_{p,M} \end{bmatrix}$$

Levenberg Marquardt 法

- LM法: 誤差逆伝播法とガウス・ニュートン法の混合

$$\Delta \mathbf{w}^{(k)} = -\left(\left(\mathbf{J}^{(k)T} \mathbf{J}^{(k)} + \mu^{(k)} \mathbf{I}\right)^{-1} \mathbf{J}^{(k)T} \mathbf{e}^{(k)}\right)$$

- 誤差が増大するとき、 μ を増大させる。LMはBPに近くなる
- 誤差が減少するとき、 μ を減少させる。LMはガウス・ニュートンに近くなる

- 利点:**
 - 収束が早い
 - 安定している
- 欠点:**
 - 計算量が多い

K. Levenberg, "A method for the solution of certain problems in least squares," *Quarterly of Applied Mathematics*, 5, pp. 164-168, 1944.
D. Marquardt, "An algorithm for least-squares estimation of nonlinear parameters," *SIAM J. Appl. Math.*, vol. 11, no. 2, pp. 431-441, Jun. 1963.

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のニューラルネットワーク
 - リカレント、DNN、補足: 中間層表現
 - ESN

75

Feedforward ANNs: 表現力とバイアス

- 表現力**
 - 隠れ層1のfeedforward ANN
 - 任意の Boolean function が実現できる("できる"ことは自明。AND-OR ネットワークを真似)
 - 任意の 有界連続関数 bounded continuous function (任意精度で近似) [Funahashi, 1989; Cybenko, 1989; Hornik et al., 1989]
 - シグモイド関数(でなくともよい): 基底関数 basis functions; (ほぼ)局所的な和で関数近似
 - ANNs が近似容易な関数: Network Efficiently Representable Functions (NERFs) - 特徴づけはできていない [Russell and Norvig, 1995]
- ANNs の帰納バイアス**
 - 多次元ユークリッド空間 (結合荷重の空間 weight space)
 - 連続関数 (荷重パラメータに関して連続)
 - 選択バイアス: 訓練事例の "滑らかな内挿"
 - よくは分かっていない

76

ANNs の過学習

- 復習: 過学習の定義
 - '/' は h と比較して、worse on D_{train} , better
- 過学習: ある型
 - 繰り返し過ぎ
 - 回避: 停止条件
(cross-validation: holdout, k-fold)
 - 回避策: weight decay

Error versus epochs (Example 1)

Error versus epochs (Example 2)

77

ANNs の過学習

- 過学習の考えられる他の原因
 - 予め設定する隠れ素子数の個数
 - 少なすぎると、十分に学習できない ("underfitting")
 - 成長不足
 - 連想: 連立方程式で、式(NNモデル)の個数(自由度)より変数(真の概念)の個数が多い
 - 多すぎると過学習
 - 枝刈りされていない
 - 連想: 2次多项式をより高次の多项式で近似する
- 解
 - 予防: 属性部分集合選択 attribute subset selection (pre-filter または wrapper)
 - 回避
 - cross-validation (CV)
 - Weight decay: エポックごとに荷重を一定値で(絶対値を)減少させる
 - 発見/回復: random restarts: 初期値をランダムにかけて、荷重や素子の addition and deletion
- 過学習は存在しない(非常に小さい確率でのみ存在する)という議論がある

S. Amaral, N. Murata, K.-R. Müller, M. Finken und H. H. Yang, Asymptotic Statistical Theory of Overtraining and Cross-Validation, IEEE Transactions on Neural Networks, Vol. 8, No. 5, pp. 985-996, 1997.

正則化項の例

- 大きな荷重にペナルティを

$$E(\vec{w}) = \sum_{d \in D} \sum_{k \in \text{outputs}} (t_{k,d} - o_{k,d})^2 + \gamma \sum_{i,j} w_{j,i}^2$$

- 関数の傾きも学習対象

$$E(\vec{w}) = \sum_{d \in D} \sum_{k \in \text{outputs}} \left[(t_{k,d} - o_{k,d})^2 + \mu \sum_{j \in \text{inputs}} \left(\frac{\partial t_{k,d}}{\partial x_d^j} - \frac{\partial o_{k,d}}{\partial x_d^j} \right)^2 \right]$$

79

目次

- パーセプトロン
 - 実は、1素子
- 多層パーセプトロン
- 学習アルゴリズム
 - ネットワークの種類
 - 誤差最小化
 - 誤差逆伝播
 - 収束の例図
 - LM法
- 表現力と過学習
- その他のネットワーク
 - リカレント、DNN、補足: 中間層表現
 - ESN

80

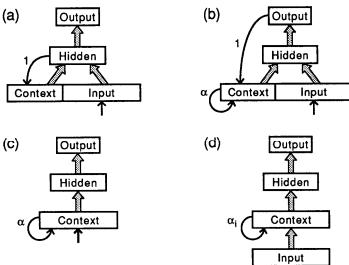
その他のニューロンモデル

- リカレント(再帰型)ニューラルネットワーク
 - 時系列の学習に利用
- Deep learning neural network
 - 中間層数 ≥ 2
 - 非常に誤解されている(2~3ぐらいは意見が分かれるが)

81

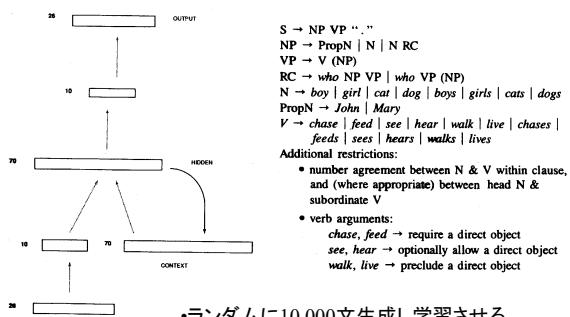
相互結合(recurrent)

- 階層型 + フィードバック(離散時間遅れ)



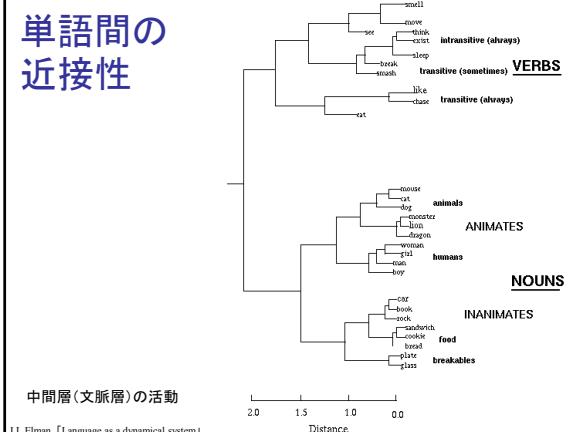
82

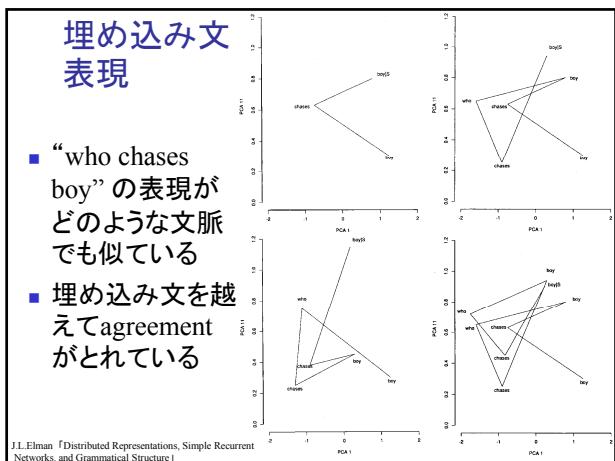
リカレントニューラルネットワーク 文法の学習(Elman)



J.L.Elman 「Distributed Representations, Simple Recurrent Networks, and Grammatical Structure」

単語間の近接性





Deep Learning

GIGAOM EVENTS RESEARCH SIGN IN SUBSCRIBE Search

DARPA is working on its own deep-learning project for natural-language processing

by Derrick Harris May 2, 2014 - 10:49 AM PDT

SUMMARY: The Defense Advanced Research Projects Agency, or DARPA, is building a set of technologies to help it better understand human language so it can search through vast amounts of unstructured text and other forms of data more effectively.

DETAILS: DARPA's new project, called "Text-to-Text Translation," will involve training neural networks to learn how to translate one language into another. The agency has already rolled out new features for its Cortana virtual assistant app, including the ability to track...

Related stories

Microsoft Cortana: Mobile virtual assistant and, now, concert hookup

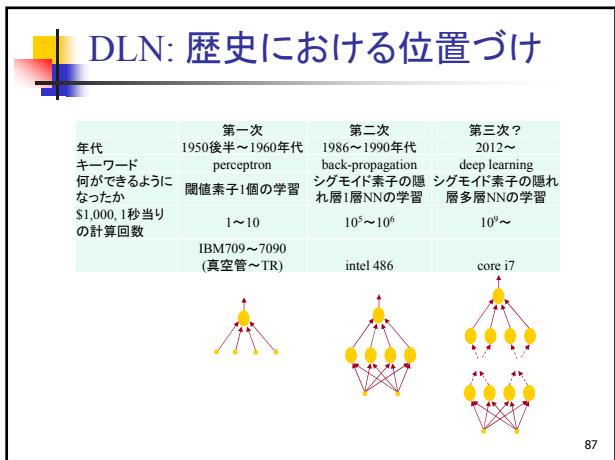
Microsoft rolled out new features for its Cortana virtual assistant app, including the ability to track...

Researchers are using deep learning to predict how we pose. It's more important than sounds

When it comes to large organizations working on artificial intelligence systems for

Find threads softw... sp... Listen...

86

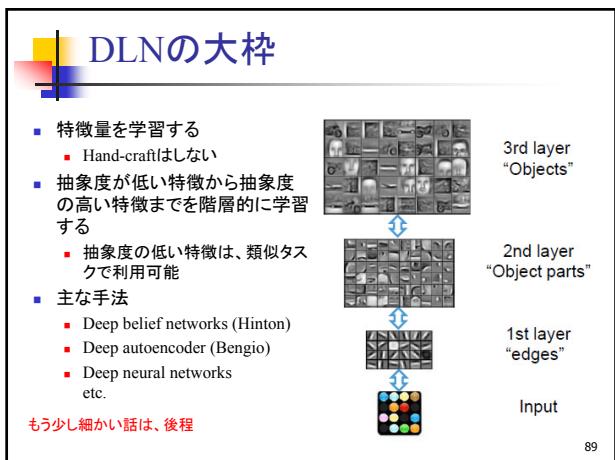


タイトル(?)総なめ

Audio		Images	
TIMIT Phone classification	Accuracy	TIMIT Speaker identification	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%
		CIFAR Object classification	Accuracy
		Prior art (Krizhevsky, 2010)	78.9%
		Stanford Feature learning	81.5%
		NORB Object classification	Accuracy
		Prior art (Renato et al., 2009)	94.4%
		Stanford Feature learning	97.3%
		Video	
		Hollywood2 Classification	Accuracy
		Prior art (Laptev et al., 2004)	48%
		Stanford Feature learning	53%
		KTH Accuracy	
		Prior art (Wang et al., 2010)	92.1%
		Stanford Feature learning	93.0%
		YouTube	Accuracy
		Prior art (Liu et al., 2009)	71.2%
		Stanford Feature learning	75.8%
		UCF	Accuracy
		Prior art (Wang et al., 2010)	85.6%
		Stanford Feature learning	86.5%
Multimodal (audio/video)			
AVLetters Lip reading		Accuracy	
Prior art (Zhao et al., 2009)		58.9%	
Stanford Feature learning		65.8%	
Other unsupervised feature learning records:			
Pedestrian detection (Yann LeCun)			
Different phone recognition task (Geoff Hinton)			
PASCAL VOC object classification (Kai Yu)			

Andrew Ng

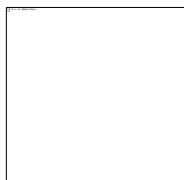
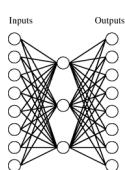
88



- ## 補足：中間層に発現する表現
- 中間層には、プログラマが意図しなかった内部表現が発生することがある
 - よくよく見ると「意味深い」表現であったりする
 - 実は、オンライン逐次学習法を用いるとBayes学習的なことがおこり、「情報の圧縮」すなわち、「意味抽出」が行われることが示せる
- 90

中間層での表現

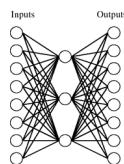
- これは学習できるか？



91

中間層での表現(2)

- 学習結果

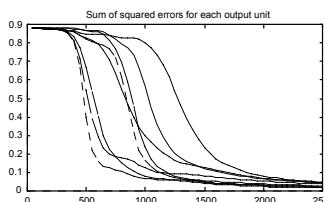


Input							Output
10000000	→	.89	.04	.08	→	10000000	
01000000	→	.01	.11	.88	→	01000000	
00100000	→	.01	.97	.27	→	00100000	
00010000	→	.99	.97	.71	→	00010000	
00001000	→	.03	.05	.02	→	00001000	
00000100	→	.22	.99	.99	→	00000100	
00000010	→	.80	.01	.98	→	00000010	
00000001	→	.60	.94	.01	→	00000001	

92

隠れ層での表現(3)

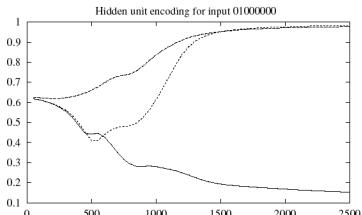
- 学習の進行の様子



93

隠れ層での表現(4)

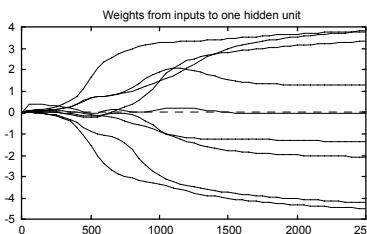
- 学習の進行の様子(2)



94

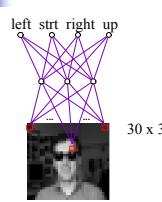
隠れ層での表現(5)

- 学習の進行の様子(3)



95

古い例: 顔画像の学習



- 顔画像の例

96

顔画像の学習

■ 学習後の荷重

left strt right up
30 x 32

97

そのほかのニューロンモデル2

- 状態をもったニューロン
 - Neuroids [Valiant, 1994]
 - それぞれの基本素子が状態をもつ
 - それぞれの更新規則は異なってもよい（または状態に基づく異なる計算）
 - 適応的なネットワークモデル
 - ランダムグラフの構造
 - 基本素子は学習過程の一部として意味も受取る
- パルス・コーディング
 - スパイク・ニューロン spiking neurons [Maass and Schmitt, 1997]
 - 活動度が出力の表現ではない
 - 発火の列間の相のずれが意味をもつ
 - 古い時間コーディング temporal coding では rate coding が用いられ、それは活動度で表現可能
- 新しい更新規則
 - 非加算的更新 [Stein and Meredith, 1993; Seguin, 1998]
 - スパイク・ニューロン・モデル spiking neuron model

98

ESN: 少し変わったNN

ESN: Echo State Network
Jaeger H. and Haas, H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication. Science, 304:78-80, 2004.

K input units N internal units L output units

内部ユニットの出力

結合加重

隠れ層と出力層: 可変

その他: ランダムに決定し、以降固定

$$x(n+1) = f(W^{in}u(n+1) + Wx(n) + W^{back}y(n))$$

101

ESNの学習例

入力: $u(n) = \sin(n/5) \rightarrow 10\pi$ の間隔で入力・教師データを取得
出力: $y(n)_{teach} = 1/2 \sin^7(n/5)$

1. データ入力 2. 教師データとのMSEを計算 3. MSEを最小化する結合加重を計算

隠れ層内部: 0.0 +0.4 -0.4 ≈ 0.95 0.025 0.025 の確率で決定
入力層と隠れ層: 1-1に等確率で決定
フィードバック結合: 1-1に等確率で決定

100

ESNの学習例: The Mackey Glass system

- Chaotic attractorの学習... dynamical system の学習のためのテスト。ポピュラーだが難しい
 $\dot{y}(t) = \alpha y(t-\tau)/(1+y(t-\tau)^\beta) - \gamma y(t)$
- パラメータは以下のように設定
 $\alpha = 0.2, \beta = 10, \gamma = 0.1$
• Mildな動き $\tau = 17$ • Wildな動き $\tau = 30$
- 離散化
 $y(n+1) = y(n) + \delta \left(\frac{0.2y(n-\tau/\delta)}{1+y(n-\tau/\delta)^{10}} - 0.1y(n) \right)$

101

学習するデータ例

Mildな動き $\tau = 17$ Wildな動き $\tau = 30$

内部ユニットの出力: ノイズ入り

$$x(n+1) = (1 - \delta Ca)x(n) + \delta C(f(W^{in}u(n+1) + Wx(n) + W^{back}y(n) + \nu(n)))$$

102

