

情報意味論(5) パーセプトロン

理工学部管理工学科
櫻井彰人

神経回路網


ニューラルネットワーク


- 動物の神経・神経回路にヒントを得る
- 人工の神経素子(neuron)とそのネットワーク
 - 多くの場合はソフトウェアで実現
- 適応する、学習する
- 連続値が扱える

今回

- 概要
- パーセプトロン

McCulloch-Pitts モデル(1943)





シグモイド素子

$$net = \sum_{i=0}^n w_i x_i$$

$$o = \sigma(net) = \sigma\left(\sum_{i=0}^n w_i x_i\right)$$

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

基本的な計算

出力 $y_{Out} = f(w_1^3, y^2)$

入力 x_1, x_2, x_3, x_4

$$y^2 = \begin{pmatrix} y_1^2 \\ y_2^2 \\ y_3^2 \end{pmatrix}, \begin{matrix} y_1^2 = f(w_1^2, y^1) \\ y_2^2 = f(w_2^2, y^1) \\ y_3^2 = f(w_3^2, y^1) \end{matrix}$$

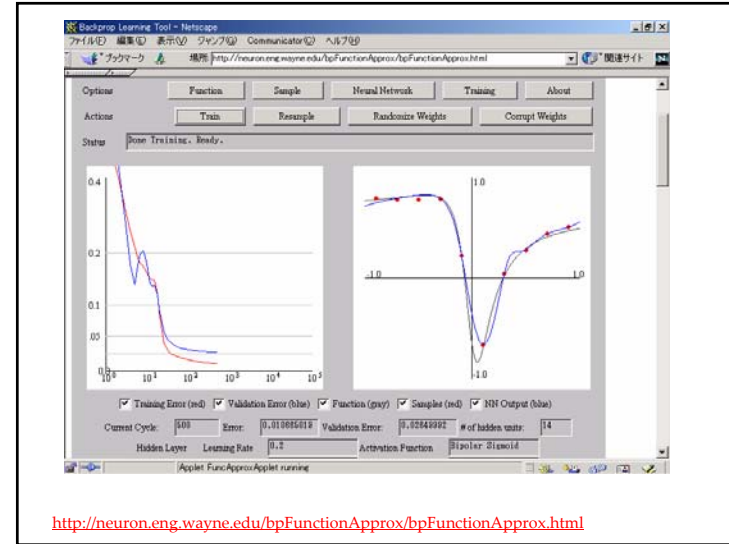

$$y^1 = \begin{pmatrix} y_1^1 \\ y_2^1 \\ y_3^1 \\ y_4^1 \end{pmatrix}, \begin{matrix} y_1^1 = f(w_1^1, x_1) \\ y_2^1 = f(w_2^1, x_2) \\ y_3^1 = f(w_3^1, x_3) \\ y_4^1 = f(w_4^1, x_4) \end{matrix}$$

ニューラルネットの原理

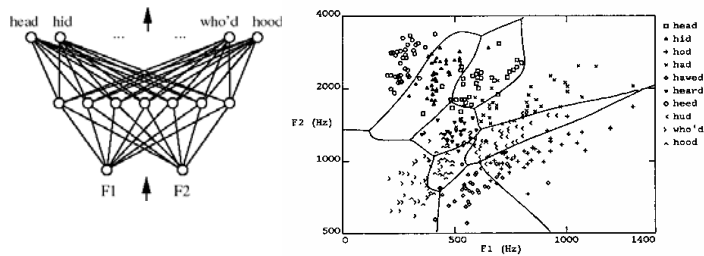
- 一側面: 関数近似・回帰である
- 例: 1入力・1出力とする

近似定理

- ニューラルネットワークの中間素子数を必要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



音声認識




<http://www-2.cs.cmu.edu/afs/cs.cmu.edu/project/theo-3/www/ml.html>

領域と境界面

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)			

連想


- (A,a), (B,b), (C,c),... というデータを記憶し、(A,?) と聞かれたら ?=a と答える
- 変形した・ノイズの乗った図形から元の図を復元する。



<http://www.physics.syr.edu/courses/modules/MM/sim/hopfield.html>

Hopfieldネットワーク

- 相互結合型。通常、時を刻みながら、過去の自分達の値を入力として、次の出力(これが次の入力となる)を決める。




Kohonenマップ

- 説明省略


<http://rths8012.fh-regensburg.de/~saj39122/jfroehl/diplom/e-sample.html>

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、これが本当!
 - シグモイド素子: 次回
 - 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。次回
 - 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 1-44
- 元祖パーセプトロン
 - Rosenblatt 1962
 - Minsky and Papert 1969




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 線形閾値素子 Linear Threshold Unit (LTU) or Linear Threshold Gate (LTG)
 - 素子への純入力 net input: 線形関数 $\text{net} = \sum_{i=0}^n w_i x_i$
 - 素子の出力: 純入力に閾値関数 threshold function を施したもの (閾値 threshold $\theta = w_0$)
 - 純入力に施して出力を得る関数を 活性化関数 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): 下の方

パーセプトロンの決定境界



- 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
 - 論理関数 (McCulloch and Pitts, 1943)
 - e.g., 簡単な荷重で $AND(x_1, x_2)$, $OR(x_1, x_2)$, $NOT(x)$
- 表現できない関数もある
 - e.g., 線型分離可能でないもの
 - 解: パーセプトロンのネットワーク

パーセプトロン学習アルゴリズム

- 学習規則 = 訓練規則 training Rule
 - 教師付き学習に特有の話ではない
 - 文脈: モデルの更新
- Hebbの学習規則 Hebbian Learning Rule (Hebb, 1949)
 - アイデア: もし2個の素子が両方とも active ("firing")であれば, 結合荷重は増加する
 - $w_{ij} = w_{ij} + r o_i o_j$, 但し r は学習係数 learning rate で, 定数である
 - 神経生理学的に, ほぼ, 指示されている
- パーセプトロン学習アルゴリズム Perceptron Learning Rule (Rosenblatt, 1959)
 - アイデア: 各入力ベクトルに対して出力値が与えられているなら, 荷重を漸進的に更新することにより, 当該出力値が出力できるようになる
 - 2値出力 (Bool値, Boolean-valued) を仮定; 単一パーセプトロン素子
 - $w_i \leftarrow w_i + \Delta w_i$
 - $\Delta w_i = r(t - o)x_i$
 - 但し $t = c(x)$ は目標出力値, o はパーセプトロンの現在の出力値, r は学習係数, 正定数であれば何でも良い, 1でよいので, 実は, パーセプトロン学習アルゴリズムでは, r は不要
 - D が線型分離可能 linearly separable であれば, 収束する. 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

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 ($D \equiv \{ \langle x, t(x) \rangle \}$)
 - 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 $o(x)$ を計算
 - FOR $i = 1$ to n
 - $w_i \leftarrow w_i + r(t - o)x_i$ // perceptron learning rule. r is any positive #
- パーセプトロン学習可能性
 - 復習: $h \in H$ のときのみ学習可能 - i.e., 線型分離可能 linearly separable (LS) functions
 - 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, どこまで真実か。

線型分離

定義


- $f(x) = 1$ if $w_1x_1 + w_2x_2 + \dots + w_mx_m \geq \theta$, 0 otherwise
- 0: 閾値

線型分離可能性

- 注: D が線型分離可能だからといって, 真の概念 $c(x)$ が線型分離可能とは限らない
- 選言 disjunction: $c(x) = x_1 \vee x_2 \vee \dots \vee x_m$
- m of n : $c(x) =$ at least 3 of (x_1, x_2, \dots, x_m)
- 排他的 exclusive OR (XOR): $c(x) = x_1 \oplus x_2$
- 一般の DNF: $c(x) = T_1 \vee T_2 \vee \dots \vee T_m$; $T_i = l_1 \wedge l_2 \wedge \dots \wedge l_k$

表現の変換

- 線型分離可能でない問題を線型分離可能な問題に変換できるか?
- それは意味のあることなのか? 現実的なのか?
- 現実問題の重要な部分を占めるのか?



✓ Linearly Separable (LS) Data Set

✓

✓

✗

✗

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
- 証明: 探索空間が限界のある順序をなしている ("楔の幅" 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

よりロバストに、またより表現力を上げるには?

- 目的 1: もっとも良い近似を発見するアルゴリズムの開発
- 目的 2: 表現の制約を超える新しいアーキテクチャの開発