

平成28年度前期
電子情報工学科5年生

人工知能 ニューラルネットワーク

中山 謙二

1

1. パーセプトロン

◆ 特徴


- 1個のニューロンからなるニューラルネットワーク
- 線形分離可能な問題(*)に適用
(*)1個の超平面で分離される問題
2次元データ → 直線
3次元データ → 平面
4次元以上のデータ → 超平面

2

◆ 入出力関係

- 入力ポテンシャル
 $u = w_0x_0 + w_1x_1 + w_2x_2$
 $x_0 = 1$

- 出力信号
 $y = f(u)$




- 非線形関数: $f(\cdot)$
 - (1) ステップ関数 $y = f(u) = \begin{cases} 1, & u > 0 \\ -1 \text{ or } 0, & u < 0 \end{cases}$ (1)
 - (2) シグモイド関数 $y = f(u) = \frac{1}{1 + e^{-u}}$ (2)
 - (3) $\tanh(\cdot)$ $y = f(u) = \frac{1 - e^{-u}}{1 + e^{-u}}$ (3)

3

◆ 直線(境界)の決め方

- 1本の直線で□と○を分離する。
- 直線は境界データ(*)からの距離が最大となるように決める。(*)直線(境界)の近くに位置するデータ。
- 上記の決め方は学習データの回りに分布する未学習データを分類するのに最も有効である。(汎化能力)



4

◆ 直線の式について


- 入力ポテンシャル
 $u = w_0x_0 + w_1x_1 + w_2x_2, \quad x_0 = 1$
- 直線(境界線)の式($u = 0$)
 $w_0x_0 + w_1x_1 + w_2x_2 = 0$
 $x_2 = -\frac{w_1}{w_2}x_1 - \frac{w_0}{w_2}$
- 直線の式を $x_2 = ax_1 + b$ としたときの w_i の計算式
 $w_2 = \text{正の任意の値}, \quad w_1 = -w_2a, \quad w_0 = -w_2b$
- $0 < w_2$ とすることにより,
直線(境界線)より上側にあるデータ → $0 < u$
直線(境界線)より下側にあるデータ → $0 > u$

5

2. 階層形ニューラルネットワーク

パーセプトロンで分離できない問題
(1本の直線で分離できない問題)

線形分離不可能な問題
↓
階層形ニューラルネットワーク



6

2層形ニューラルネットワーク

◆ 入出力関係

隠れ層(ニューロン)


$$u_1 = w_{10}x_0 + w_{11}x_1 + w_{12}x_2 \cdots (1)$$

$$u_2 = w_{20}x_0 + w_{21}x_1 + w_{22}x_2 \cdots (2)$$

$$x_0 = 1$$

$$y_1 = f(u_1)$$

$$y_2 = f(u_2)$$



出力層(ニューロン)

$$v = w_0y_0 + w_1y_1 + w_2y_2 \cdots (3)$$

$$y_0 = 1$$

$$z = f(v)$$

7

演習問題1

1. 式(1)と(2)の直線($u_1 = u_2 = 0$)と境界データの距離が最大となるように w_{ji} を決め、直線を図示せよ。

2. 1で求めた w_{ji} を用いたときの y_1, y_2 を求めて、プロットせよ(横軸: y_1 , 縦軸: y_2). □と○で表示する。但し、非線形関数は次のステップ関数とする。

$$f(u) = \begin{cases} 1, & u > 0 \\ -1, & u < 0 \end{cases}$$

3. 式(3)の直線($v = 0$)と境界データの距離が最大となるように w_j を決めよ。また、この直線を図示せよ。

4. 1と3で求めた w_{ji}, w_j を用いたときの z の値を求めよ。

8

階層形ニューラルネットワークの学習

◆ 線形モデルで考える

$$y(n) = w_1(n)x_1(n) + w_2(n)x_2(n)$$

$$e(n) = d(n) - y(n) \quad d: \text{目標値}$$

$$J(w) = e^2(n) = (d(n) - y(n))^2$$

誤差関数 $J(w)$ は $w_1(n), w_2(n)$ の2次形式(放物曲面)

最急降下法

$$w_i(n+1) = w_i(n) - \frac{\mu}{2} \cdot \frac{\partial J(w)}{\partial w_i(n)}$$

(板書で説明)

9

2層形ニューラルネットワークの学習アルゴリズム

◆ 隠れ層 $\rightarrow w_j \rightarrow$ 出力層

$$w_j(n+1) = w_j(n) - \frac{\mu}{2} \cdot \frac{\partial J(w)}{\partial w_j(n)}$$

$$J(w) = e^2$$

$$e = d - z \quad d: \text{目標値}$$

$$z = f(v)$$

$$v = w_0y_0 + w_1y_1 + w_2y_2, \quad y_0 = 1$$

$$\frac{\partial J(w)}{\partial w_j} = \frac{dJ(w)}{de} \cdot \frac{de}{dz} \cdot \frac{dz}{dv} \cdot \frac{\partial v}{\partial w_j}$$

$$= 2e \cdot (-1) \cdot f'(v) \cdot y_j$$

$$w_j(n+1) = w_j(n) + \mu \cdot e(n) \cdot f'(v(n)) \cdot y_j(n)$$

10

◆ 入力層 $\rightarrow w_{ji} \rightarrow$ 隠れ層

$$w_{ji}(n+1) = w_{ji}(n) - \frac{\mu}{2} \cdot \frac{\partial J(w)}{\partial w_{ji}(n)}$$

$$J(w) = e^2$$

$$e = d - z$$

$$z = f(v)$$

$$v = w_0y_0 + w_1y_1 + w_2y_2, \quad y_0 = 1$$

$$y_j = f(u_j)$$

$$u_j = w_{j0}x_0 + w_{j1}x_1 + w_{j2}x_2$$

$$\frac{\partial J(w)}{\partial w_{ji}} = \frac{dJ(w)}{de} \cdot \frac{de}{dz} \cdot \frac{dz}{dv} \cdot \frac{\partial v}{\partial y_j} \cdot \frac{\partial y_j}{\partial u_j} \cdot \frac{\partial u_j}{\partial w_{ji}}$$

$$= 2e \cdot (-1) \cdot f'(v) \cdot w_j \cdot f'(u_j) \cdot x_i$$

$$w_{ji}(n+1) = w_{ji}(n) + \mu \cdot e(n) \cdot f'(v(n)) \cdot w_j(n) \cdot f'(u_j(n)) \cdot x_i(n)$$

11

◆ 非線形関数の微分

➢ シグモイド関数

$$f'(v) = \left(\frac{1}{1+e^{-v}} \right)' = \frac{e^{-v}}{(1+e^{-v})^2}$$

$$= \frac{1}{1+e^{-v}} \left(1 - \frac{1}{1+e^{-v}} \right) = z(1-z)$$

➢ tanh()

$$f'(v) = \left(\frac{1-e^{-v}}{1+e^{-v}} \right)' = \frac{e^{-v}(1+e^{-v}) + (1-e^{-v})e^{-v}}{(1+e^{-v})^2}$$

$$= \frac{2e^{-v}}{(1+e^{-v})^2} = \frac{1}{2} \left(1 + \frac{1-e^{-v}}{1+e^{-v}} \right) \left(1 - \frac{1-e^{-v}}{1+e^{-v}} \right)$$

$$= \frac{1}{2} (1+z)(1-z)$$

特徴: ニューロンの出力(FF計算:後述)で計算できる。

12

◆ 階層形ニューラルネットワークの学習の流れ

<ステップ1>

入力層→隠れ層→出力層(フィードフォワード:FF)におけるニューロンの入力ポテンシャルと出力信号の計算

$$\begin{aligned} u_1(n) &= w_{10}(n)x_0 + w_{11}(n)x_1(n) + w_{12}(n)x_2(n) \\ u_2(n) &= w_{20}(n)x_0 + w_{21}(n)x_1(n) + w_{22}(n)x_2(n) \\ x_0 &= 1 \\ y_1(n) &= f(u_1(n)) \\ y_2(n) &= f(u_2(n)) \\ v(n) &= w_0(n)y_0 + w_1(n)y_1(n) + w_2(n)y_2(n) \\ y_0 &= 1 \\ z(n) &= f(v(n)) \\ e(n) &= d(n) - z(n) \quad d(n) = \text{目標値} \end{aligned}$$

13

<ステップ2>

出力層→隠れ層→入力層(フィードバック:FB)の順に結合重み(係数)の学習

① $w_j(n)$ (隠れ層→出力層)の学習

$$w_j(n+1) = w_j(n) + \mu \cdot e(n) \cdot f'(v(n)) \cdot y_j(n)$$

上式において、 $e(n), y_j(n)$ はFF計算で求まっている。 $f'(v(n))$ もFF計算で求まった $z(n)$ により計算できる。

② $w_{ji}(n)$ (入力層→隠れ層)の学習

$$w_{ji}(n+1) = w_{ji}(n) + \mu \cdot e(n) \cdot f'(v(n)) \cdot w_j(n) \cdot f'(u_j(n)) \cdot x_i(n)$$

上式においても、必要な値は与えられているか、またはFF計算で求まっている。 $e(n) \cdot f'(v(n)) \cdot w_j(n)$ は等価的な誤差→誤差逆伝搬法(Error Back Propagation: BP法)

14

3 リカレント形ニューラルネットワーク

ホップフィールドネットワーク

◆ 特徴

- 結合重みが対象である $w_{ji} = w_{ij}$
- 自己ループがない $w_{ii} = 0$
- 状態遷移: 1個のニューロンがランダムに選択されて状態を更新する。
- あるエネルギー関数が存在し、ニューロン1個の状態変化において、このエネルギー関数は変わらないか減少する(増加しない)。

15

◆ ニューロンの状態遷移


1個のニューロン(j 番目)がランダムに選択され、次式によりその状態(s_j)を更新する。

$$\begin{aligned} u_j(n) &= w_{j1}s_1(n) + w_{j2}s_2(n) + w_{j3}s_3(n), w_{jj} = 0 \\ s_j(n+1) &= \begin{cases} 1, & u_j(n) > 0 \\ s_j(n), & u_j(n) = 0 \\ -1, & u_j(n) < 0 \end{cases} \end{aligned}$$

初期状態 $s_j(0)$ は問題に応じて決める。

(例)

ランダムなパターン
記憶パターン+雑音



16

◆ 重み係数の設計法

ニューロン数は N 、ネットワークに記憶するパターンを $p_1 \sim p_M$ (記憶パターン数 = M) とする。 p_k の要素は ± 1 である。

$$W = \frac{1}{N} \sum_{k=1}^M p_k \cdot p_k^T - \frac{M}{N} I$$

W は $N \times N$ 行列で、 j 行 i 列の要素は w_{ji} である。

W は対称行列 ($w_{ji} = w_{ij}$) であり、かつ、対角要素は零となる ($w_{jj} = 0$)。

17

(例題)

$$N = 3, M = 2$$

$$p_1 = \begin{bmatrix} 1 \\ -1 \\ 1 \end{bmatrix}, \quad p_2 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}$$

$$\begin{aligned} W &= \frac{1}{3} \begin{bmatrix} 1 \\ -1 \\ 1 \end{bmatrix} [1, -1, 1] + \frac{1}{3} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} [-1, 1, -1] - \frac{2}{3} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \\ &= \frac{1}{3} \begin{bmatrix} 2 & -2 & 2 \\ -2 & 2 & -2 \\ 2 & -2 & 2 \end{bmatrix} - \frac{2}{3} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 0 & -2 & 2 \\ -2 & 0 & -2 \\ 2 & -2 & 0 \end{bmatrix} \end{aligned}$$

以上より、

$$w_{12} = w_{21} = -\frac{2}{3}, w_{13} = w_{31} = \frac{2}{3}$$

$$w_{23} = w_{32} = -\frac{2}{3}, w_{jj} = 0$$

18

状態遷移の例

n	u_1	u_2	u_3	s_1	s_2	s_3	
0				1	1	1	初期状態
1	0	(-)	0	1	-1	1	安定状態(記憶パターンを連想)
2	+	-	+	1	-1	1	

n	u_1	u_2	u_3	s_1	s_2	s_3	
0				1	1	-1	初期状態
1	(-)	0	0	-1	1	-1	安定状態(記憶パターンを連想)
2	-	+	-	-1	1	-1	

$$\left\{ \begin{array}{l} [1, 1, 1] \\ [-1, -1, 1] \\ [1, -1, -1] \end{array} \right\} \rightarrow [1, -1, 1] \quad \left\{ \begin{array}{l} [-1, -1, -1] \\ [-1, 1, 1] \\ [1, 1, -1] \end{array} \right\} \rightarrow [-1, 1, -1]$$

19

エネルギー関数

$$E(n) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ji} s_i(n) s_j(n), \quad w_{ii} = 0$$

1個のニューロンの状態変化に対して、 $E(n)$ は「変化しない」か「減少する」のいずれかであり、増加することはない。その為、ニューロンの状態遷移を繰り返すことにより $E(n)$ は極小値に落ち着く。

$E(n)$ の極小値に記憶パターンを対応させる(*)ことにより連想記憶システムを構築できる。

(*) 前述の重み係数の設計法が一つの方法

20

エネルギー関数の例題(3ニューロンの場合)

$$w_{12} = w_{21}, w_{13} = w_{31}, w_{23} = w_{32} \text{ であるから}$$

$$E(n) = -[w_{12}s_1(n)s_2(n) + w_{13}s_1(n)s_3(n) + w_{23}s_2(n)s_3(n)]$$

$s_1(n)$ が変化したとする。

$$s_1(n+1) = s_1(n) + \Delta s_1(n+1)$$

$$E(n+1) = -[w_{12}s_1(n)s_2(n) + w_{13}s_1(n)s_3(n) + w_{23}s_2(n)s_3(n)] - \Delta s_1(n+1)[w_{12}s_2(n) + w_{13}s_3(n)] = E(n) + \Delta E(n+1)$$

$$u_1(n) = w_{12}s_2(n) + w_{13}s_3(n) \text{ であるから}$$

$$\Delta E(n+1) = -\Delta s_1(n+1)u_1(n)$$

21

エネルギー関数 $E(n)$ の変化

$$u_1(n) > 0 \rightarrow \Delta s_1(n+1) \geq 0 \rightarrow \Delta E(n+1) \leq 0$$

$$u_1(n) = 0 \rightarrow \Delta s_1(n+1) = 0 \rightarrow \Delta E(n+1) = 0$$

$$u_1(n) < 0 \rightarrow \Delta s_1(n+1) \leq 0 \rightarrow \Delta E(n+1) \leq 0$$

このように、1個のニューロンの状態変化により生じるエネルギー関数の変化 $\Delta E(n+1)$ は零または負であり、増加することはない。

22

演習問題2

3ニューロンから成るホップフィールドネットワークにおいて、次の2つのパターンを記憶する場合を考える。

$$N = 3, M = 2$$

$$p_1 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}, \quad p_2 = \begin{bmatrix} -1 \\ -1 \\ 1 \end{bmatrix}$$

1. 結合重み w_{ji} を求めよ。
2. 全てのパターンを初期状態として、状態遷移の過程とその結果(安定状態)を求めよ。
3. 状態遷移の様子を直方体上に示せ。

23

4. $[-1, 1, -1]$ と $[1, 1, -1]$ におけるエネルギー E を求めて、比較せよ。同様に $[1, -1, 1]$ と $[-1, -1, 1]$ についてもエネルギーを求めて比較せよ。
5. 2と3において、全てのニューロンの状態を同時に変化させたときの結果を示せ。
(参考)ホップフィールドネットワークとは違う方法であり、ある状態に落ち着くことは保証されていない。

24

演習問題3

入力データ $x_1(n), x_2(n)$ に対する出力を $y(n)$ とし、目標値を $d(n)$ とする。勾配法(最急降下法)により $w_1(n), w_2(n)$ を更新する式を求めよ。

式は $w_i(n), x_i(n), y(n), d(n)$ を用いて表せ。

$$y(n) = w_1(n)x_1(n) + w_2(n)x_2(n)$$

$$e(n) = d(n) - y(n) \cdots \text{誤差}$$

$$J(w) = e^2(n) \cdots \text{誤差関数}$$

$$w_i(n+1) = w_i(n) - \frac{\mu}{2} \cdot \frac{\partial J(w)}{\partial w_i(n)} \cdots (1)$$

$$\frac{\partial J(w)}{\partial w_i(n)} = \frac{dJ(w)}{de(n)} \cdot \frac{de(n)}{dy(n)} \cdot \frac{dy(n)}{dw_i(n)}$$

25

演習問題4

パーセプトロンにおいて、入力データ $x_1(n), x_2(n)$ に対する出力を $y(n)$ とし、目標値を $d(n)$ とする。

$$u(n) = w_1(n)x_1(n) + w_2(n)x_2(n)$$

$$y(n) = f(u(n)) = \begin{cases} 1, & u(n) \geq 0 \\ -1, & u(n) < 0 \end{cases}$$

$$e(n) = d(n) - y(n)$$

$w_1(n), w_2(n)$ を次式で更新することにより、誤差 $e(n)$ が減少することを示せ。

$$w_i(n+1) = w_i(n) + \mu e(n)x_i(n), 0 < \mu \cdots (*)$$

(場合分け)

$$(1) e(n) > 0, x_i(n) > 0 \quad (3) e(n) < 0, x_i(n) > 0$$

$$(2) e(n) > 0, x_i(n) < 0 \quad (4) e(n) < 0, x_i(n) < 0$$

26

演習問題5

ホップフィールドネットワークによる連想記憶に関して以下の間に答えよ。但し、ニューロン数を4個とする。Excelプログラムを用いて計算すること。

- 4個の記憶パターン $p_1 \sim p_4$ を決定せよ(次頁に例題)。
- 記憶パターンが安定度を求めよ。
安定度 = 安定である記憶パターン数 / 4
- 16通りの初期パターンに対する収束パターンを求めよ。
- 収束パターンが記憶パターンである場合は「連想成功」、そうでない場合は「不成功」とし、次の成功率を求めよ。
成功率 = (成功した初期パターン数) / 16
- 記憶パターンを変えて2~4を繰り返せ(3通り)。
- 上記の結果から、記憶パターンの組合せと安定度、成功率の関係について考察せよ(ハミング距離が関係)。

29