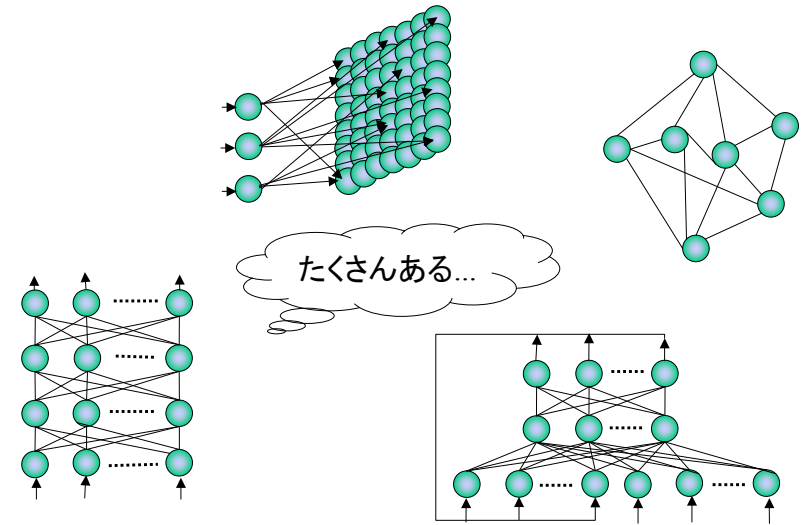


# ニューラルネットワークの話

真部 雄介

# ニューラルネットワークの例



# ニューラルネットワークを見る3つの観点

- **構造(つながり方)**
  - 階層型 or 相互結合型
- **信号の流れ方(計算順序)**
  - フィードバックあり(リカレント) or フィードバックなし(フィードフォワード)?
- **学習法**
  - 教師あり(supervised)学習 or 教師なし(unsupervised)学習?

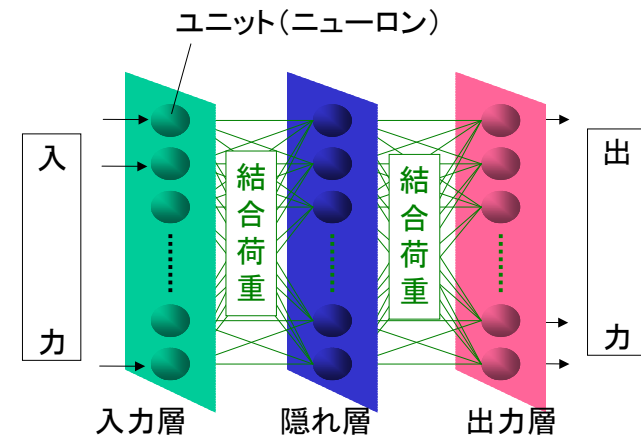


様々なモデルがあつてキリがないので...

最も代表的な、「教師あり学習」「階層型」「フィードフォワード」のニューラルネットワークを説明します。


# ニューラルネットワーク

- 「教師あり学習」「階層型」「フィードフォワード」の
- ニューラルネットワークの例




## ニューロンの動作(1/2)


- ニューロンモデル (McCullochとPitts [1943])



$$u = \sum_{i=1}^n w_i x_i \quad o = \begin{cases} 1, & (u > \theta) \\ 0, & (u \leq \theta) \end{cases}$$




$$u' = \sum_{i=1}^n w_i x_i - \theta \quad o = \begin{cases} 1, & (u' > 0) \\ 0, & (u' \leq 0) \end{cases}$$




## ニューロンの動作(2/2)

- ニューロンモデル改



$$\begin{aligned} u' &= \sum_{i=1}^n w_i x_i - \theta \\ &= \sum_{i=1}^n w_i x_i + (-\theta) * 1 \\ &= \sum_{i=1}^n w_i x_i + \theta \end{aligned}$$

$$o = f(u') = \frac{1}{1 + e^{-u'}}$$



これをいっばいつなげて構造化すると

**ニューラル ネットワーク**


## ニューラルネットの計算過程

- p: 入力データパターン数
- $i_{px}$ : pパターン目のユニットxへの入力値
- $t_p$ : pパターン目の教師データ
- $w_{xy}$ : ユニットxy間の結合荷重
- $o_{px}$ : pパターン目のユニットxの出力値
- $b_x$ : ユニットxのバイアス荷重(閾値)

$$\begin{aligned} o_{p1} &= i_{p1}, o_{p2} = i_{p2} \\ o_{p3} &= f(u3), u3 = o_{p1} * w_{13} + o_{p2} * w_{23} + b_3 \\ o_{p4} &= f(u4), u4 = o_{p1} * w_{14} + o_{p2} * w_{24} + b_4 \\ o_{p5} &= f(u5), u5 = o_{p3} * w_{35} + o_{p4} * w_{45} + b_5 \\ f(x) &= 1 / (1 + \exp(-x)) \end{aligned}$$



$w_{xy} \in W, b_x \in B$ を調整し、 $(i_{p1}, i_{p2}) \in I_p$ が入力された時の $o_{p5}$ を $t_p$ に近づけたい!



## 何ができるのか

「教師あり学習」「階層型」「フォワードフォワード」の

**ニューラルネットワークは...**

任意の複雑な入力と出力の関係性(関数)を  
任意の精度で実現することのできる学習モデル

おおざっぱにいうと




**関数近似マシン**

とって使っています

## 関数を作る(1)


### ■ 例)ブラックボックスAをつくる



こんな箱Aを作りたい!


$x=1$ のとき,  $y=2$   
 $x=2$ のとき,  $y=4$   
 $x=3$ のとき,  $y=6$   
 $x=4$ のとき,  $y=8$   
 $x=5$ のとき,  $y=10$

$x$ と $y$ の対応づけを  
実現する $A(x)$ とは?



## 関数を作る(2)


### ■ 例)ブラックボックスBをつくる



こんな箱Bを作りたい!

$x=1$ のとき,  $y=0.1$   
 $x=2$ のとき,  $y=2.9$   
 $x=3$ のとき,  $y=5$   
 $x=4$ のとき,  $y=2.5$   
 $x=5$ のとき,  $y=1.3$



$x$ と $y$ の対応づけを  
実現する $B(x)$ とは?



## 世の中は複雑な関数だらけ

### ■ ロボットの行動

■ 環境 → センサ → 内部処理 → モーター → 行動

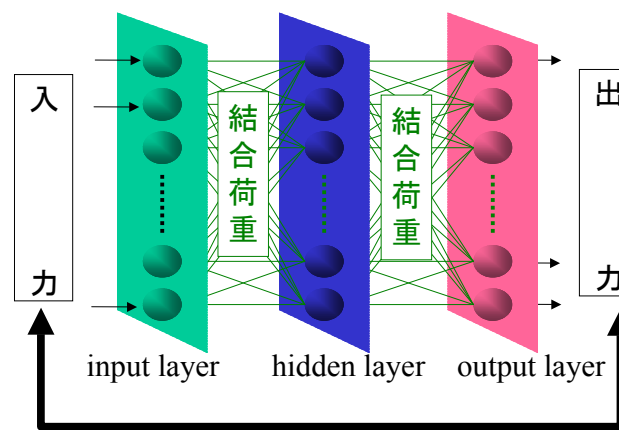


入力 出力

複雑な入力と出力の関数でも対応づけを実現したい

ニューラルネットワークなら可能

## ニューラルネットの学習 = 関数近似



入力と出力の対応付けを実現すること = 学習  
関数を作る(関数近似)

## 入出力関係(関数)の実現の仕方

### ■ 自分が実現したい入力と出力の関係を表わすデータを用意する

#### ■ 例1) ブラックボックスB

- (入力, 出力) = {(1, 0.1), (2, 2.9), (3, 5), (4, 2.5), (5, 1.3)}

学習データパターン(これは5パターン)

入力データ 教師データ

#### ■ 例2) 入力/出力は、もちろん多変数でもOK.

- (入力, 出力) = {(1, 2), 1), ((2, 3), 5), ((2, 1), 3), ((3, 4), 5)}

2入力1出力

### ■ そのデータを使って関数を作る(学習する)

- 結合荷重を調整して、入出力の対応づけを実現する
- 誤差逆伝播学習法(バックプロパゲーション学習法)が有名

## 最急降下法(1/3)

例)  $y = f(x) = \frac{1}{2}(x-1)^2$  という関数がある。このyができるだけ

小さくなるようなxを求めよ。



数値解法的に求める→最急降下法

### 最急降下法の手順

- ① xの初期値を適当に決める。
- ② その時の傾きを求める。
- ③ 傾きに応じてxの値をyが小さくなるように少し修正する。
- ④ 修正した値を次のxとして②に戻る。


## 最急降下法(2/3)

①  $x=2$ とする

②  $x=2$ のときの傾きは、

$$y = \frac{1}{2}(x-1)^2 \quad f'(x) = \frac{dy}{dx} = (x-1) \text{より}$$

$$f'(2) = 1$$



③

$$x^{new} = x + \Delta x$$

$$\Delta x = -\eta \frac{dy}{dx}$$

とすればyが小さくなる方へxが修正される!  $\eta$ : 学習係数

$\eta = 0.3$ とすると

$$x^{new} = 2 - 0.3 * 1 = 1.7$$

x=2のとき

y=0.5

x=1.7のとき

y=0.245

確かにyが小さくなった!

## 最急降下法(3/3)

④  $x=1.7$ として再度計算。順次計算していくと...

$$x=1.7, \text{ 傾き } 0.7, x^{new} = 1.7 - 0.3 * 0.7 = 1.49$$

$$x=1.49, \text{ 傾き } 0.49, x^{new} = 1.49 - 0.3 * 0.49 = 1.343$$

$$x=1.343, \text{ 傾き } 0.343, x^{new} = 1.343 - 0.3 * 0.343 = 1.2401$$

$$x=1.2401, \text{ 傾き } 0.2401, x^{new} = 1.2401 - 0.3 * 0.2401 = 1.16807$$

.....

xが最小値0に近づいていく!

## 誤差逆伝播学習

ニューラルネットの目的:  $o_{p5}$  を  $t_p$  に近づけたい!

$$E = \sum_{p=1}^N E_p \quad E_p = \frac{1}{2} (o_{p5} - t_p)^2$$

$E_p$ :  $p$  番目の学習データパターンに対する  
出力層の出力値と教師データの誤差  
 $E$ : トータルの誤差



各学習パターンの誤差を小さくする =  $E_p$  を小さくする

→  $E_p = \frac{1}{2} (o_{p5} - t_p)^2$  を小さくするように  $W$  を修正する!

## 誤差逆伝播学習

$$\begin{aligned} x^{new} &= x + \Delta x & w_{ij}^{new} &= w_{ij}^{old} + \Delta w_{ij} \\ \Delta x &= -\eta \frac{dy}{dx} & \Delta w_{ij} &= -\eta \frac{\partial E_p}{\partial w_{ij}} \end{aligned}$$

例1)  $w_{45}$  の修正量は

$$\Delta w_{45} = -\eta \frac{\partial E_p}{\partial w_{45}} = -\eta \frac{\partial E_p}{\partial o_{p5}} \frac{\partial o_{p5}}{\partial u_5} \frac{\partial u_5}{\partial w_{45}} = -\eta (o_{p5} - t_p) f'(u_5) o_{p4}$$

学習信号

例2)  $w_{24}$  の修正量は

$$\begin{aligned} \Delta w_{24} &= -\eta \frac{\partial E_p}{\partial w_{24}} = -\eta \frac{\partial E_p}{\partial o_{p5}} \frac{\partial o_{p5}}{\partial u_5} \frac{\partial u_5}{\partial o_{p4}} \frac{\partial o_{p4}}{\partial u_4} \frac{\partial u_4}{\partial w_{24}} \\ &= -\eta (o_{p5} - t_p) f'(u_5) w_{45} f'(u_4) o_{p2} \end{aligned}$$

逆伝播!


## ニューラルネットの計算過程

$p$ : 入力データパターン数  
 $i_{px}$ :  $p$  パターン目のユニット  $x$  への入力値  
 $t_p$ :  $p$  パターン目の教師データ  
 $w_{xy}$ : ユニット  $xy$  間の結合荷重  
 $o_{px}$ :  $p$  パターン目のユニット  $x$  の出力値  
 $b_x$ : ユニット  $x$  のバイアス荷重 (閾値)

$$\begin{aligned} o_{p1} &= i_{p1}, o_{p2} = i_{p2} \\ o_{p3} &= f(u_3), u_3 = o_{p1} * w_{13} + o_{p2} * w_{23} + b_3 \\ o_{p4} &= f(u_4), u_4 = o_{p1} * w_{14} + o_{p2} * w_{24} + b_4 \\ o_{p5} &= f(u_5), u_5 = o_{p3} * w_{35} + o_{p4} * w_{45} + b_5 \\ f(x) &= 1 / (1 + \exp(-x)) \end{aligned}$$



$w_{xy} \in W, b_x \in B$  を調整し、 $(i_{p1}, i_{p2}) \in I_p$  が入力された時の  $o_{p5}$  を  $t_p$  に近づけたい!



## まとめると

$$\begin{aligned} w_{ij}^{new} &= w_{ij}^{old} + \Delta w_{ij} \\ &= w_{ij}^{old} - \eta \frac{\partial E_p}{\partial w_{ij}} & i: \text{対象としている層のユニット番号} \\ &= w_{ij}^{old} - \eta \delta_i o_j & j: \text{1つ下層のユニット番号} \end{aligned}$$

ただし、 $\delta_i = \begin{cases} (o_i - t_i) f'(u_i) & i \text{ が出力ユニット番号のとき} \\ \delta_k w_{ki} f'(u_i) & i \text{ が隠れユニット番号のとき} \\ & (k: \text{1つ上層のユニット番号}) \end{cases}$

$$\begin{aligned} f(x) &= \frac{1}{1 + e^{-x}} \\ f'(x) &= f(x)(1 - f(x)) \end{aligned}$$