

誤差逆伝播法による  
ニューラルネットワーク  
(BackPropagation  
Neural Network, BPNN)

明治大学 理工学部 応用化学科  
データ化学工学研究室 金子 弘昌

# BPNN とは？

- ✓ニューラルネットワークおよびその学習法の一つ
- ✓目的変数の誤差が小さくなるように、各ニューロンの重みを最適化
- ✓深層学習（ディープラーニング）も基本的には同じ学習方法で可能
  - ディープニューラルネットワーク
- ✓隠れ層の数が多くなると、入力変数（説明変数）に近くなるにつれて学習が進まなくなるので注意


# ニューラルネットワークの構造 1/2

入力変数  
(説明変数)

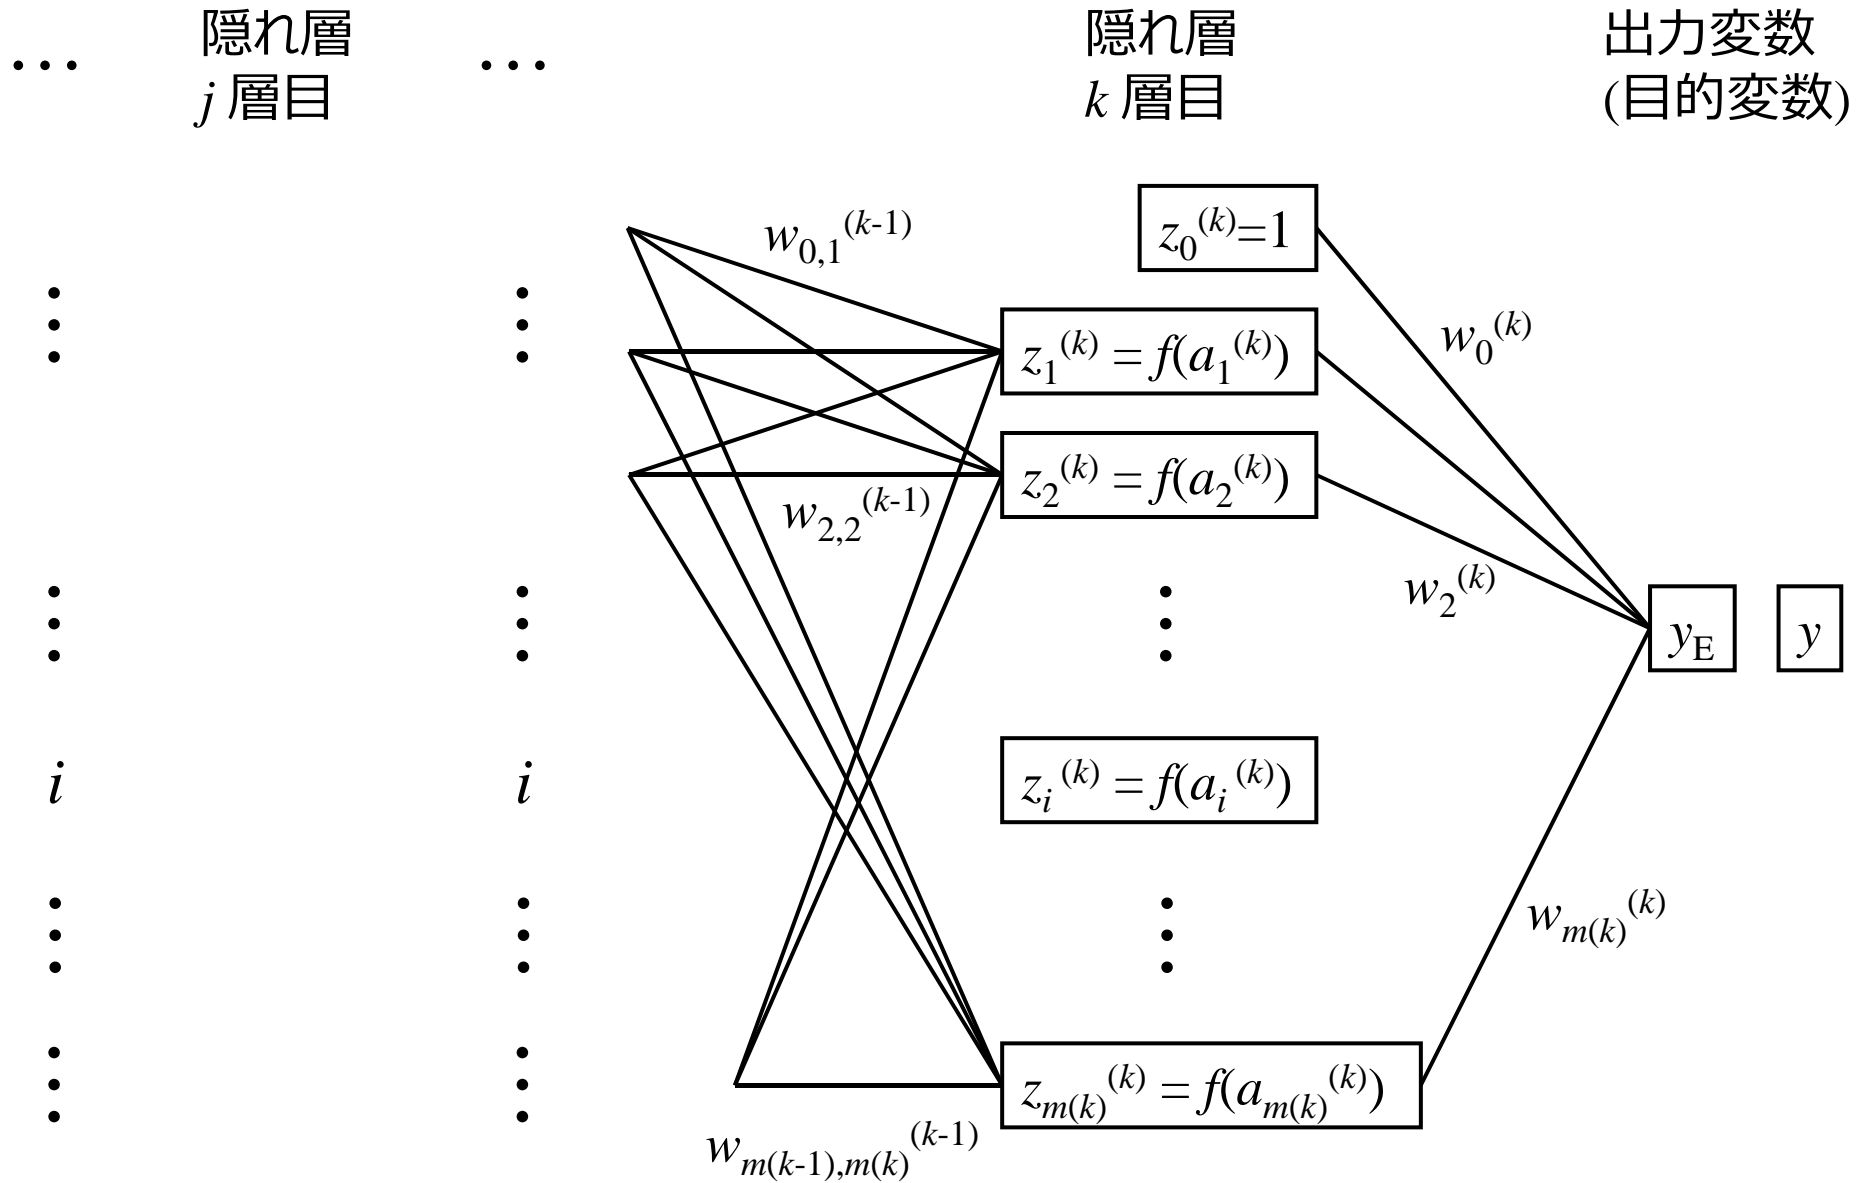
隠れ層  
1 層目

隠れ層  
2 層目

...



# ニューラルネットワークの構造 2/2



# ニューラルネットワークの構造の補足

- ✓ 入力変数 (説明変数) と隠れ層 1 層目の間や、隠れ層の前後の間や、隠れ層  $k$  層目と出力変数 (目的変数) の間の、すべての線 (ー) に重み  $w$  がある
- ✓ それぞれの隠れ層における四角 ( $z_i^{(j)} = f(a_i^{(j)})$ ) をニューロンと呼ぶ
- ✓ 入力変数 (説明変数) には  $x_0 = 1$  が、それぞれの隠れ層にも 0 番目のニューロンとして  $z_0^{(j)} = 1$  が、バイアスパラメータとしてある
- ✓ 隠れ層  $j-1$  層目の  $p$  番目のニューロンと、隠れ層  $j$  層目の  $i$  番目のニューロンとの間の重みを、 $w_{p,i}^{(j)}$  とする

# ニューラルネットワークの構造を式で表す

$$a_i^{(1)} = \sum_{p=1}^m w_{p,i}^{(0)} x_p + w_{0,i}^{(0)} = \sum_{p=0}^m w_{p,i}^{(0)} x_p \quad (x_0 = 1)$$

$$a_i^{(j)} = \sum_{p=1}^{m^{(j-1)}} w_{p,i}^{(j-1)} z_p^{(j-1)} + w_{0,i}^{(j-1)} = \sum_{p=0}^{m^{(j-1)}} w_{p,i}^{(j-1)} z_p^{(j-1)} \quad (z_0^{(j-1)} = 1)$$

$$z_i^{(j)} = f(a_i^{(j)})$$

$$y_E = \sum_{p=1}^{m^{(k)}} w_p^{(k)} z_p^{(k)} + w_0^{(k)} = \sum_{p=0}^{m^{(k)}} w_p^{(k)} z_p^{(k)} \quad (z_0^{(k)} = 1)$$

$x_i$  :  $i$  番目の入力変数 (説明変数)

$y$  : 出力変数 (目的変数)

$y_E$  : 推定された出力変数 (目的変数)

$f$  : 活性化関数

# 活性化関数の例 1/2

$$z_i^{(j)} = f(a_i^{(j)})$$

シグモイド関数

$$z_i^{(j)} = \frac{1}{1 + \exp(-a_i^{(j)})}$$

ソフトサイン

$$z_i^{(j)} = \frac{a_i^{(j)}}{1 + |a_i^{(j)}|}$$

ソフトマックス関数

$$z_i^{(j)} = \frac{\exp(a_i^{(j)})}{\sum_{p=1}^{m^{(j)}} \exp(a_p^{(j)})}$$

# 活性化関数の例 1/2

$$z_i^{(j)} = f(a_i^{(j)})$$

ReLU  
(Rectified Linear Unit)

$$z_i^{(j)} = \max(0, a_i^{(j)})$$

動径基底関数

$$z_i^{(j)} = \exp\left(-\gamma(a_i^{(j)})^2\right)$$



# 活性化関数についての補足

- ✓ 活性化関数によって、ニューラルネットワークが非線形になる
- ✓ 活性化関数は微分可能である必要がある (後述)
- ✓ 以前はシグモイド関数が多く用いられたが、近年は隠れ層の数  $k$  を多くすることもあり、ReLU やその改良版が用いられることが多い (後述)
- ✓ クラス分類のときは、出力層にソフトマックス関数を用いる
- ✓ 動径基底関数を用いたとき、RBF (Radial Basis Function) ネットワークの一つになる

# ネットワークを構築するとは？

すべての重み ( $w_p^{(k)}$  や  $w_{p,i}^{(j)}$ ) を決めるということ

決める方法の一つが、誤差逆伝播法

# 誤差逆伝播法 サンプルごとの誤差 $E$

サンプルごとの誤差  $E$  は 
$$E = \frac{1}{2}(y_E - y)^2$$

サンプルごとに  $E$  が小さくなるように、重み  $w$  を変化させていけばよい

➡  $w$  を微小変化させることでどう  $E$  が変化するか、を  
求めるため、 $E$  を  $w$  で微分する

… これにより  $w$  を変化させるべき方向 (大きくするか小さくするか) が  
求まるので、たとえば確率的勾配降下法 [1] などで重みを更新する

[1] <https://ja.wikipedia.org/wiki/確率的勾配降下法>

# 誤差逆伝播法 隠れ層 k 層目から y への重み<sup>11</sup>

$$\frac{\partial E}{\partial w_p^{(k)}} = \frac{\partial E}{\partial y_E} \frac{\partial y_E}{\partial w_p^{(k)}} \quad (\text{連鎖則}) \cdots \quad \frac{d}{dx} \log(x^2) = \frac{1}{x^2} 2x$$

でやっていることと同じ

$$\text{p. 10 より} \quad \frac{\partial E}{\partial y_E} = y_E - y$$

$$\text{p. 5 の 4 式目より} \quad \frac{\partial y_E}{\partial w_p^{(k)}} = z_p^{(k)}$$

$$\text{よって、} \quad \frac{\partial E}{\partial w_p^{(k)}} = (y_E - y) z_p^{(k)}$$

# 誤差逆伝播法 $k = 1$ のとき

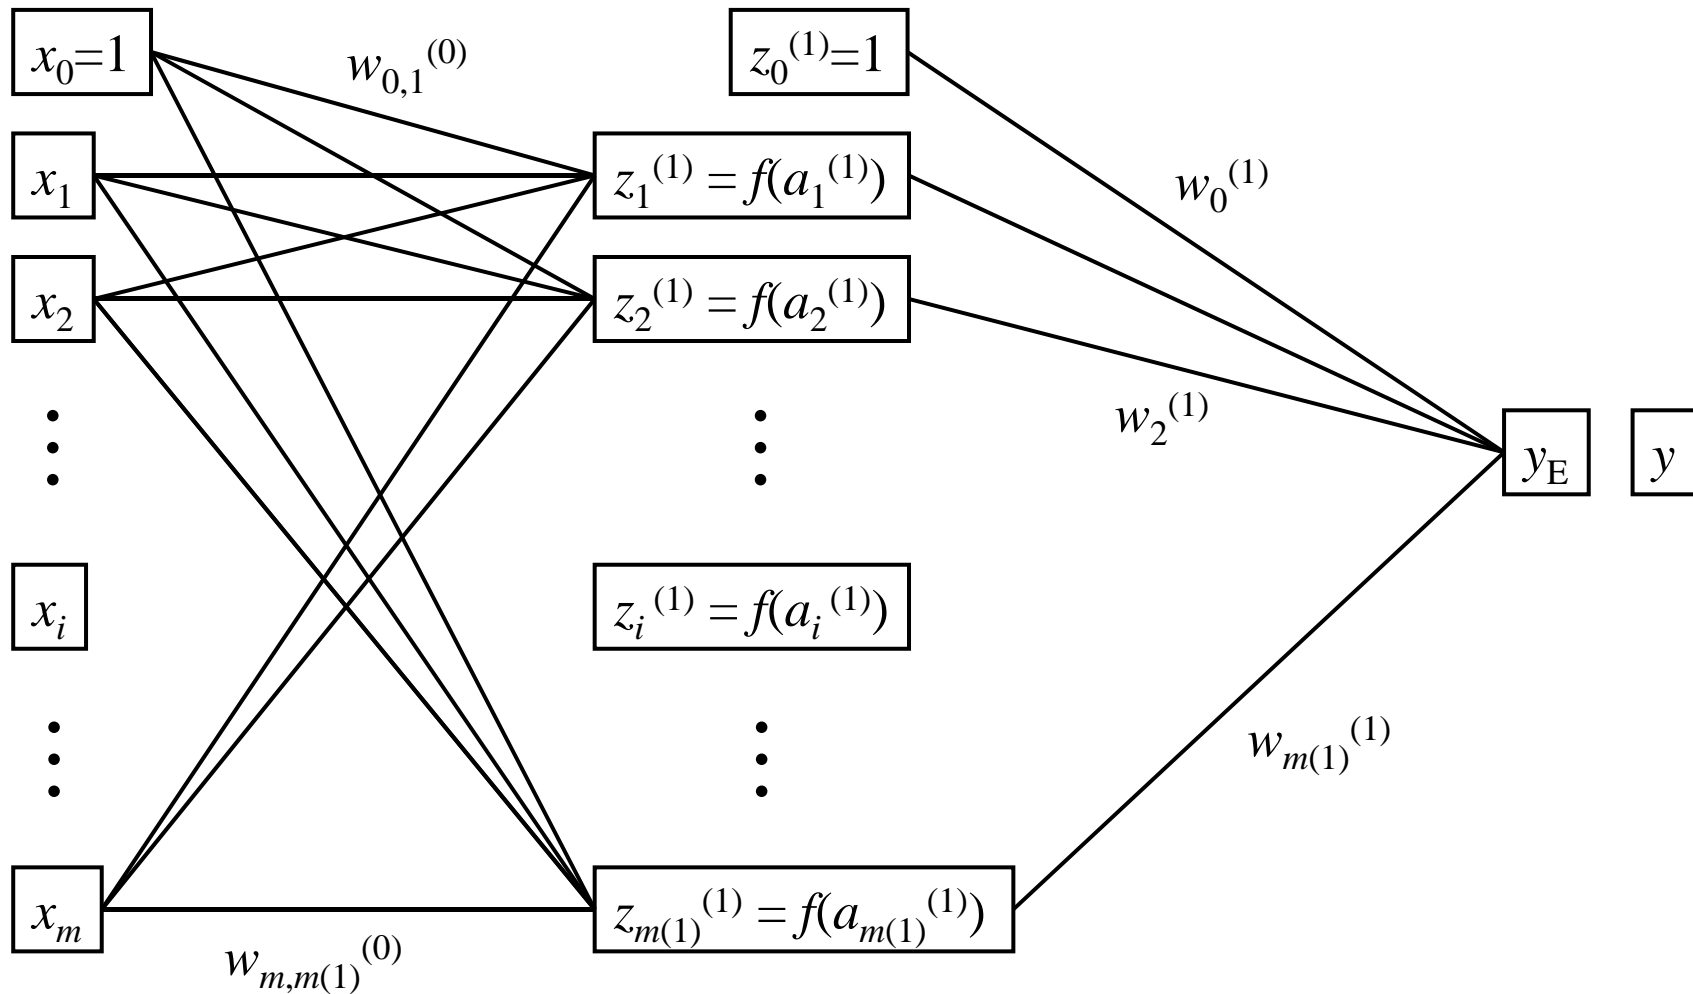
続いて、隠れ層  $j$  層目から  $j+1$  層目への重みを考えたいが、  
まずは、最も単純な  $k = 1$  つまり隠れ層が 1 層のときを考える

# ニューラルネットワークの構造 隠れ層 1 層

入力変数  
(説明変数)

隠れ層  
1 層目

出力変数  
(目的変数)



# 誤差逆伝播法 x から隠れ層 1 層目への重み<sup>14</sup>

$$\frac{\partial E}{\partial w_{p,i}^{(0)}} = \frac{\partial E}{\partial a_i^{(1)}} \frac{\partial a_i^{(1)}}{\partial w_{p,i}^{(0)}} \quad (\text{連鎖則})$$

p. 5 の 1 式目より  $\frac{\partial a_i^{(1)}}{\partial w_{p,i}^{(0)}} = x_p$

また、  $\frac{\partial E}{\partial a_i^{(1)}} = \frac{\partial E}{\partial y_E} \frac{\partial y_E}{\partial a_i^{(1)}} = (y_E - y) \frac{\partial y_E}{\partial a_i^{(1)}}$   
(連鎖則) (p. 11)

p. 5 の 4 式目より  $\frac{\partial y_E}{\partial a_i^{(1)}} = w_i^{(1)} \frac{\partial z_i^{(1)}}{\partial a_i^{(1)}}$

よって、  $\frac{\partial E}{\partial w_{p,i}^{(0)}} = x_p (y_E - y) w_i^{(1)} \frac{\partial z_i^{(1)}}{\partial a_i^{(1)}}$

# 誤差逆伝播法 活性化関数の微分

$\frac{\partial z_i^{(1)}}{\partial a_i^{(1)}}$  は、p. 6, 7 の活性化関数を  $a_i^{(j)}$  で微分して、その導関数に

$a_i^{(1)}$  を代入したもの

➡ 活性化関数は  $a_i^{(j)}$  で微分可能である必要がある



# 誤差逆伝播法 $k > 1$ のとき 1/3

隠れ層が 2 層以上するとき (ディープニューラルネットワーク)、  
隠れ層  $j-1$  層目から  $j$  層目への重みを考える

$$\frac{\partial E}{\partial w_{p,i}^{(j-1)}} = \frac{\partial E}{\partial a_i^{(j)}} \frac{\partial a_i^{(j)}}{\partial w_{p,i}^{(j-1)}} \quad (\text{連鎖則})$$

p. 5 の 2 式目より  $\frac{\partial a_i^{(j)}}{\partial w_{p,i}^{(j-1)}} = z_p^{(j-1)}$

隠れ層  $j$  層目の  $i$  番目のニューロンにつながっている、  
隠れ層  $j+1$  層目の  $m^{(j+1)}$  個のニューロンを考えると、

$$\frac{\partial E}{\partial a_i^{(j)}} = \sum_{q=1}^{m^{(j+1)}} \frac{\partial E}{\partial a_q^{(j+1)}} \frac{\partial a_q^{(j+1)}}{\partial a_i^{(j)}}$$

# 誤差逆伝播法 $k > 1$ のとき 2/3

$$\frac{\partial E}{\partial a_i^{(j)}} = \sum_{q=1}^{m^{(j+1)}} \frac{\partial E}{\partial a_q^{(j+1)}} \frac{\partial a_q^{(j+1)}}{\partial a_i^{(j)}}$$

p. 5 の 2 式目より  $a_q^{(j+1)} = \sum_{p=0}^{m^{(j-1)}} w_{p,q}^{(j)} z_p^{(j)}$  から、  $\frac{\partial a_q^{(j+1)}}{\partial a_i^{(j)}} = w_{i,q}^{(j)} \frac{\partial z_i^{(j)}}{\partial a_i^{(j)}}$

$\frac{\partial z_i^{(j)}}{\partial a_i^{(j)}}$  は、p. 6, 7 の活性化関数を  $a_i^{(j)}$  で微分して、その導関数に

$a_i^{(1)}$  を代入したもの

p. 16, 17 をまとめると、

$$\frac{\partial E}{\partial w_{p,i}^{(j-1)}} = z_p^{(j-1)} \sum_{q=1}^{m^{(j+1)}} \frac{\partial E}{\partial a_q^{(j+1)}} w_{i,q}^{(j)} \frac{\partial z_i^{(j)}}{\partial a_i^{(j)}}$$

$\frac{\partial E}{\partial a_q^{(j+1)}}$  について、p. 17 と同様にして、隠れ層  $j+1$  層目の  $q$  番目の

ニューロンにつながっている、隠れ層  $j+2$  層目の  $m^{(j+2)}$  個のニューロンを  
考えることができる

これを繰り返すと、 $j+2$  層目、 $j+3$  層目、 $\dots$ となり、最後は  $y$  になる

つまり、

$$\frac{\partial E}{\partial y_E} = y_E - y$$

# 誤差逆伝播法 名前の由来

以上のように、 $y$  の誤差  $y_E - y$  が、隠れ層  $k$  層目、 $k-1$  層目、 $\dots$  と逆に伝播して、重みの変化に寄与していることから、誤差逆伝播法と呼ぶ

# 誤差逆伝播法 注意点

$y$  の誤差が伝播するとき、隠れ層  $k$  層目、 $k-1$  層目、 $\dots$  と入力変数 (説明変数) に近くなるにつれて、値が小さくなっていくことに注意

p. 18 に活性化関数の微分係数  $\frac{\partial z_i^{(j)}}{\partial a_i^{(j)}}$  があるが、たとえば

シグモイド関数の微分係数の最大値は 0.25 であり、隠れ層の層が深くなるにつれて、最大でも  $0.25^j$  と指数関数的に小さくなっていく

➡ 重み  $w$  が変化しなくなってしまう

そこで、特に隠れ層の数  $k$  を多くするときには、微分係数が 1 になる ReLU が使われる