知の探究

5. AI-機械学習

堀田　敬介

神経細胞とニューラルネットワーク

- 神経細胞 neuron

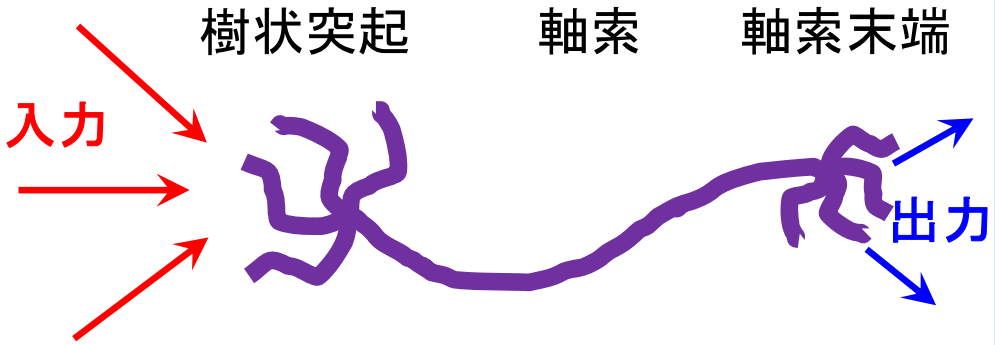

1. 樹状突起に，他の神経細胞とのシナプス synapse が多数ある
2. シナプス部位で情報を受け取る（**入力**）
3. 細胞体内で活動電位を発生させ電気信号に変換，軸索を通り軸索末端へ
4. 軸索末端が神経伝達物質を放出（次の神経細胞へ**出力**）

- ニューラルネットワーク neural network
  - 神経細胞をグラフ $G = (V, E)$ でモデル化

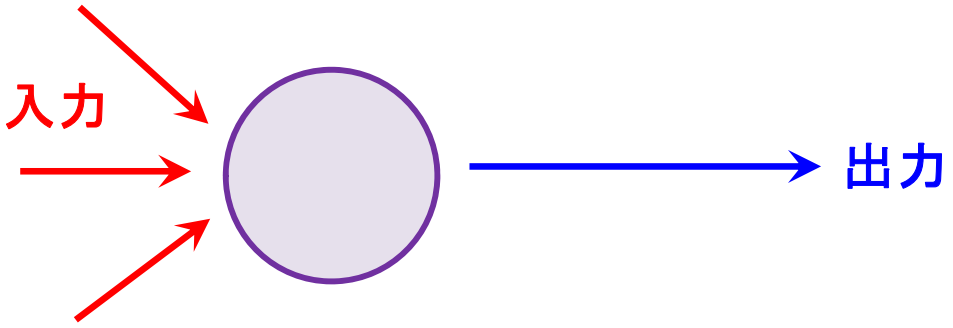

神経細胞とニューラルネットワーク

- 神経細胞 neuron

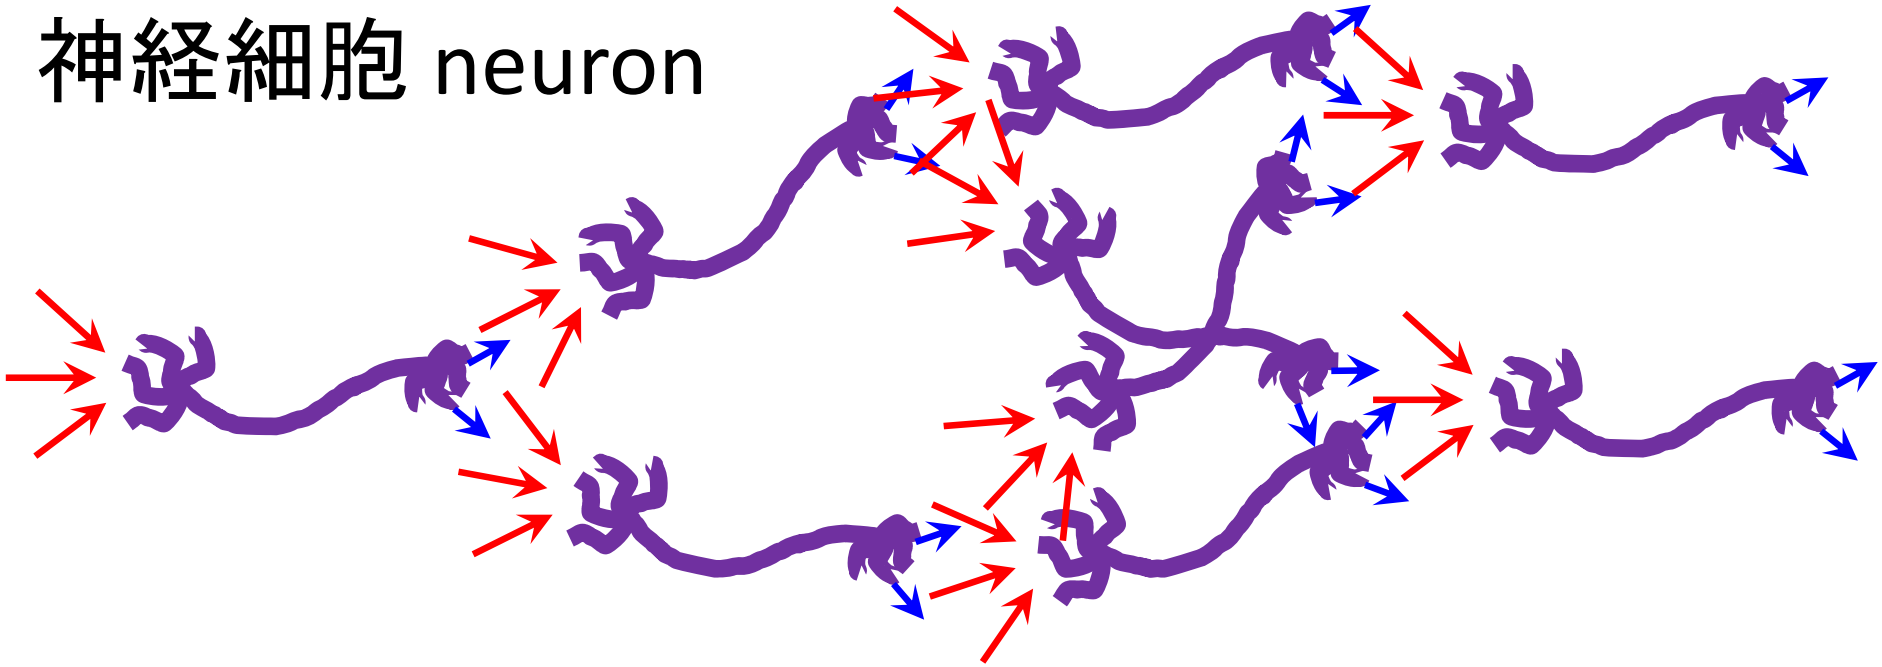

- ニューラルネットワーク neural network

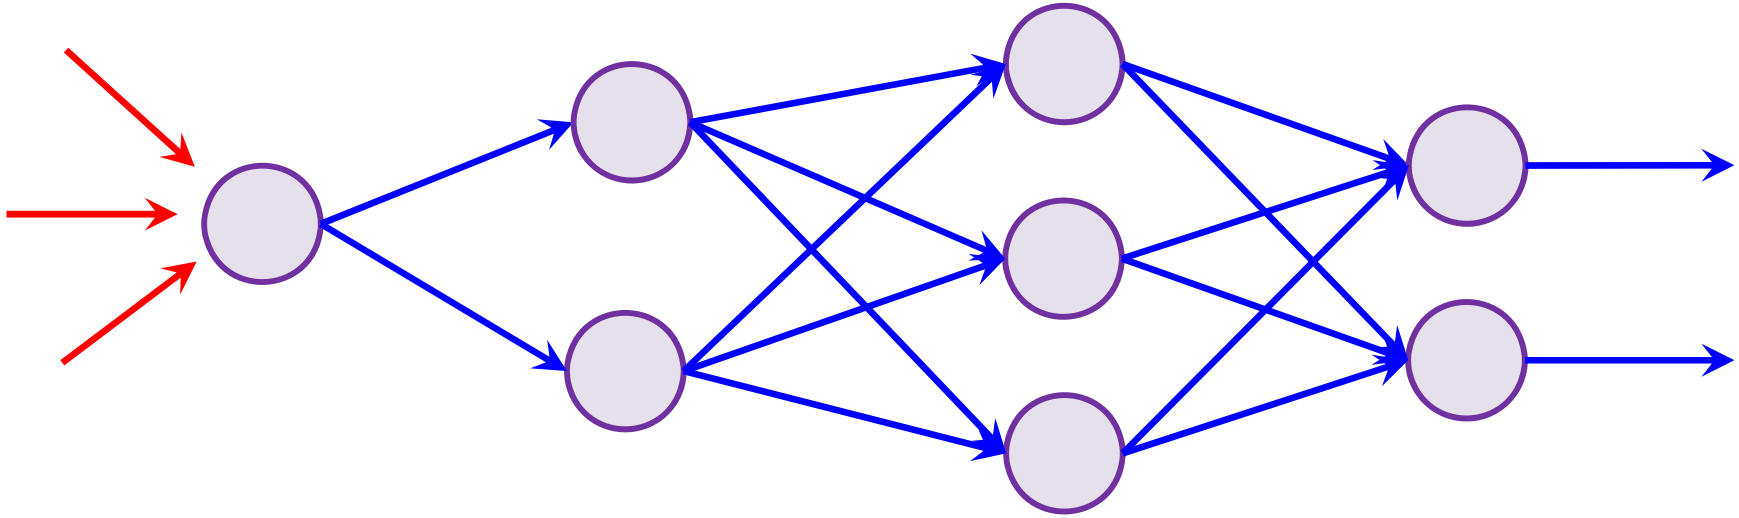

神経細胞とニューラルネットワーク

- 基本ユニットと入力から出力までの伝達（計算）

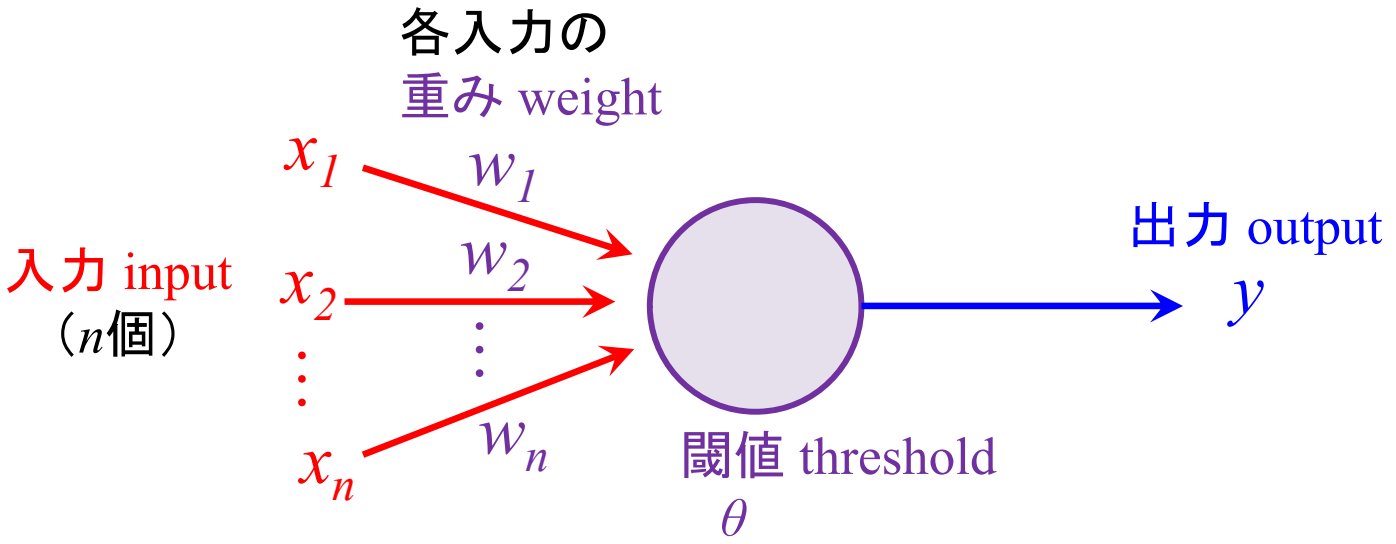

※出力値は1つだが，次の複数のユニットに伝達される

$$s = w_1x_1 + w_2x_2 + \ldots + w_nx_n - \theta$$
$$= \boldsymbol{w}^T\boldsymbol{x}$$

$$y = a(s)$$

※aは活性化関数 activation function

ただし，$\boldsymbol{w} = \begin{pmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \\ \theta \end{pmatrix}$, $\boldsymbol{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \\ -1 \end{pmatrix}$

※重みと閾値 $\boldsymbol{w}$ は各ユニットがもつ固有の値

神経細胞とニューラルネットワーク

- 活性化関数として使われる関数の例
  - シグモイド関数 sigmoid function

$$\sigma(s) = \frac{1}{1+e^{-s}} \quad \in (0,1)$$

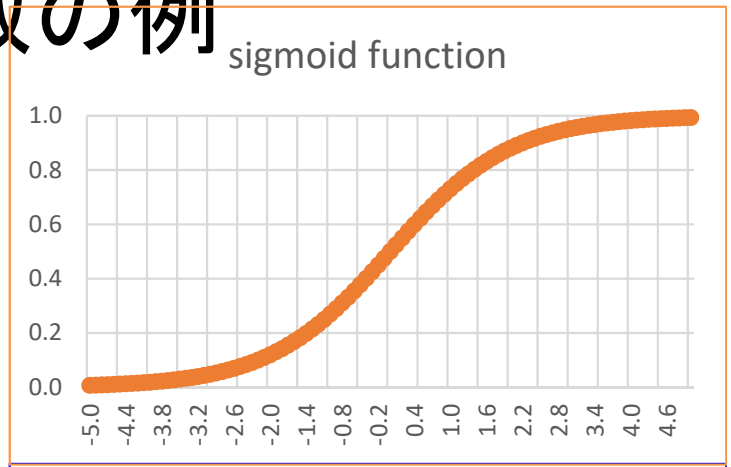

  - 双曲線正接関数 hyperbolic tangent function

$$tanh(s) = \frac{e^{s}-e^{-s}}{e^{s}+e^{-s}} \quad \in (-1,1)$$

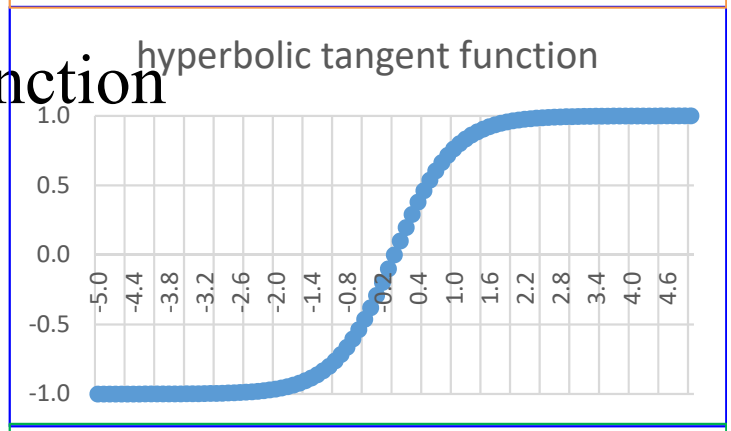

  - ランプ関数 ReLU ramp function

$$ReLU(s) = \begin{cases} s & (s \geq 0) \\ 0 & (s < 0) \end{cases}$$

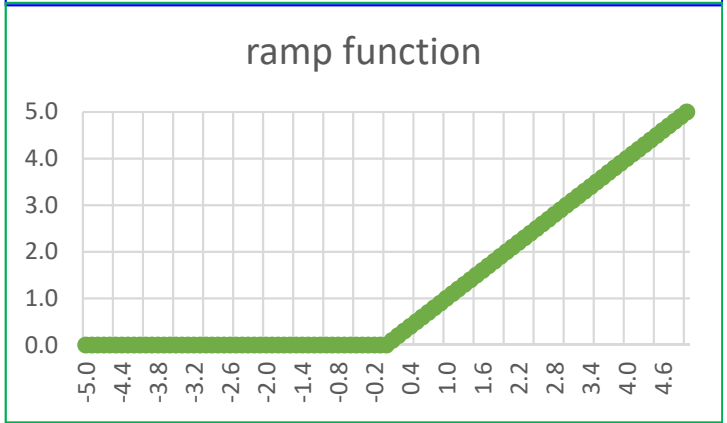

  - etc.

ニューラルネットワークと機械学習

✓ 例：4×3画素の画像識別

- 各画素は 0 or 1 の2値とする
- 画像例

0	1	1
1	0	0
1	0	0
0	1	1

1	1	1
0	1	0
0	1	0
0	1	0

- 入力（12個）となる

x_1	x_2	x_3
x_4	x_5	x_6
x_7	x_8	x_9
x_{10}	x_{11}	x_{12}

※ネットワークを多層にしたのが
深層学習 Deep Learning
＜深層学習 Deep Learning の例＞
- 畳み込みニューラルネットワーク
  CNN; Convolutional Neural Network
- 回帰型ニューラルネットワーク
  RNN; Recurrent Neural Network
- 深層強化学習　DQN; Deep Q-Network

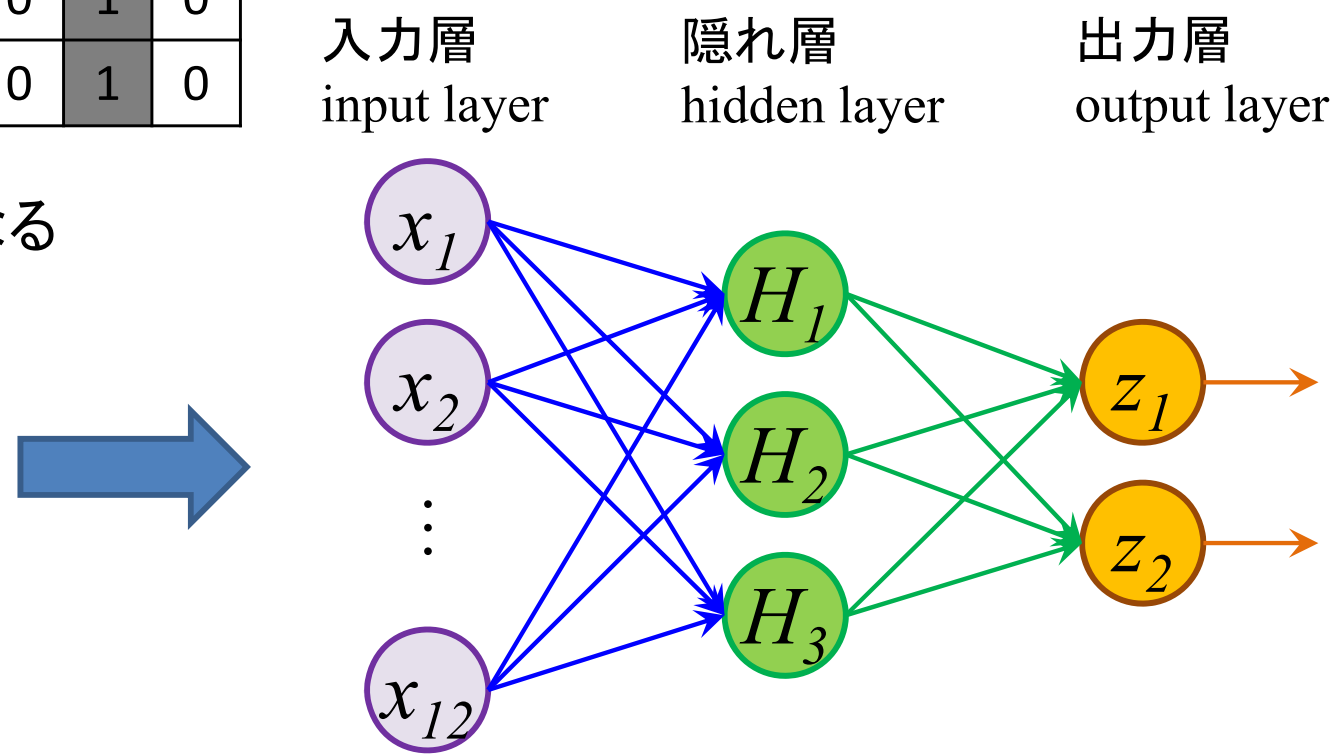

※[1]涌井・涌井「Excelでわかる機械学習超入門」技術評論社（2019） 5章

ニューラルネットワークと機械学習

➢ *input layer* → *hidden layer*

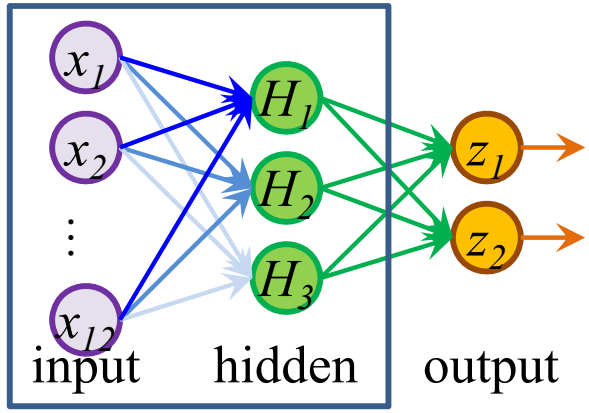

$$\begin{cases} s_1^H = w_{11}^H x_1 + \cdots + w_{12,1}^H x_{12} - \theta_1^H = (\boldsymbol{w}_1^H)^T \boldsymbol{x} \\ s_2^H = w_{12}^H x_1 + \cdots + w_{12,2}^H x_{12} - \theta_2^H = (\boldsymbol{w}_2^H)^T \boldsymbol{x} \\ s_3^H = w_{13}^H x_1 + \cdots + w_{12,3}^H x_{12} - \theta_3^H = (\boldsymbol{w}_3^H)^T \boldsymbol{x} \end{cases}$$

ただし, $\boldsymbol{w}_i^H = \begin{pmatrix} w_{1i}^H \\ w_{2i}^H \\ \vdots \\ w_{12,i}^H \\ \theta_i^H \end{pmatrix}, \boldsymbol{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_{12} \\ -1 \end{pmatrix}$

$(i = 1,2,3)$

$$\begin{cases} h_1 = a(s_1^H) \\ h_2 = a(s_2^H) \\ h_3 = a(s_3^H) \end{cases}$$

※aは活性化関数 activation function

この値を求めたい（決めたい）！
人間がこの値を設定するのではなく，
機械に自ら設定させる（＝機械学習）

ニューラルネットワークと機械学習

➢ *hidden layer* → *output layer*

$$\begin{cases} s_1^o = w_{11}^o h_1 + w_{21}^o h_2 + w_{31}^o h_3 - \theta_1^o = (\boldsymbol{w}_1^o)^T \boldsymbol{h} \\ s_2^o = w_{12}^o h_1 + w_{22}^o h_2 + w_{32}^o h_3 - \theta_2^o = (\boldsymbol{w}_2^o)^T \boldsymbol{h} \end{cases}$$

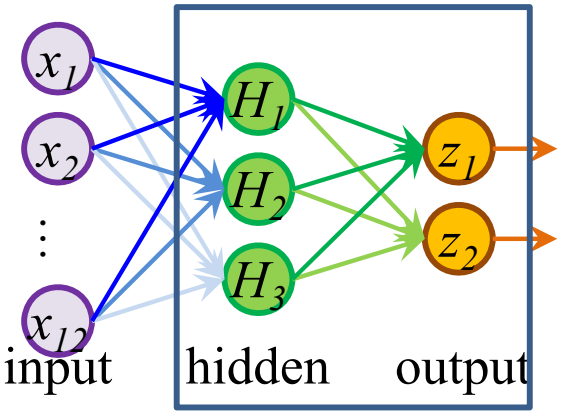

ただし, $\boldsymbol{w}_j^o = \begin{pmatrix} w_{1j}^o \\ w_{2j}^o \\ w_{3j}^o \\ \theta_j^o \end{pmatrix}$, $\boldsymbol{h} = \begin{pmatrix} h_1 \\ h_2 \\ h_3 \\ -1 \end{pmatrix}$

$$\begin{cases} z_1 = a(s_1^o) \\ z_2 = a(s_2^o) \end{cases}$$

$(j = 1,2)$

この値を求めたい（決めたい）！
人間がこの値を設定するのではなく，
機械に自ら設定させる（＝機械学習）

※aは活性化関数 activation function

ニューラルネットワークと機械学習

- *output layer* → *results*
  - 例：4×3画素の画像識別
    - z_1 … 文字「C」に反応
    - z_2 … 文字「T」に反応

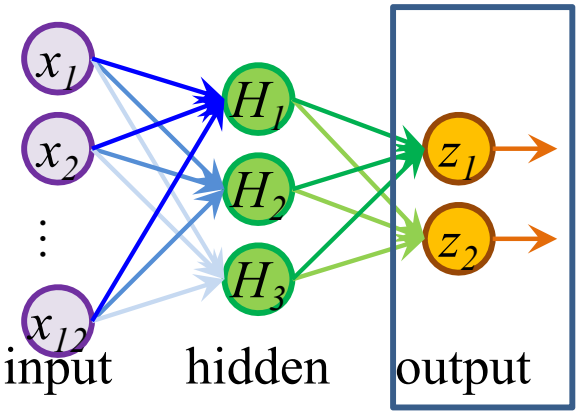

$\begin{cases} z_1 = 1 \\ z_2 = 0 \end{cases}$ →画像は「C」であると結論する

$\begin{cases} z_1 = 0 \\ z_2 = 1 \end{cases}$ →画像は「T」であると結論する

$\begin{cases} z_1 = 0 \\ z_2 = 0 \end{cases}$ →画像は「C」でも「T」でもないと結論する

- 誤差 *error*

$$e = \frac{(t_1 - z_1)^2 + (t_2 - z_2)^2}{2}$$

この誤差が最小になるように，機械に学習させる

ニューラルネットワークと機械学習

- 誤差 *error* 評価で機械学習（教師あり学習の場合）
  - 画像[入力]と正解[教師] (t_1, t_2) の組を多数準備する

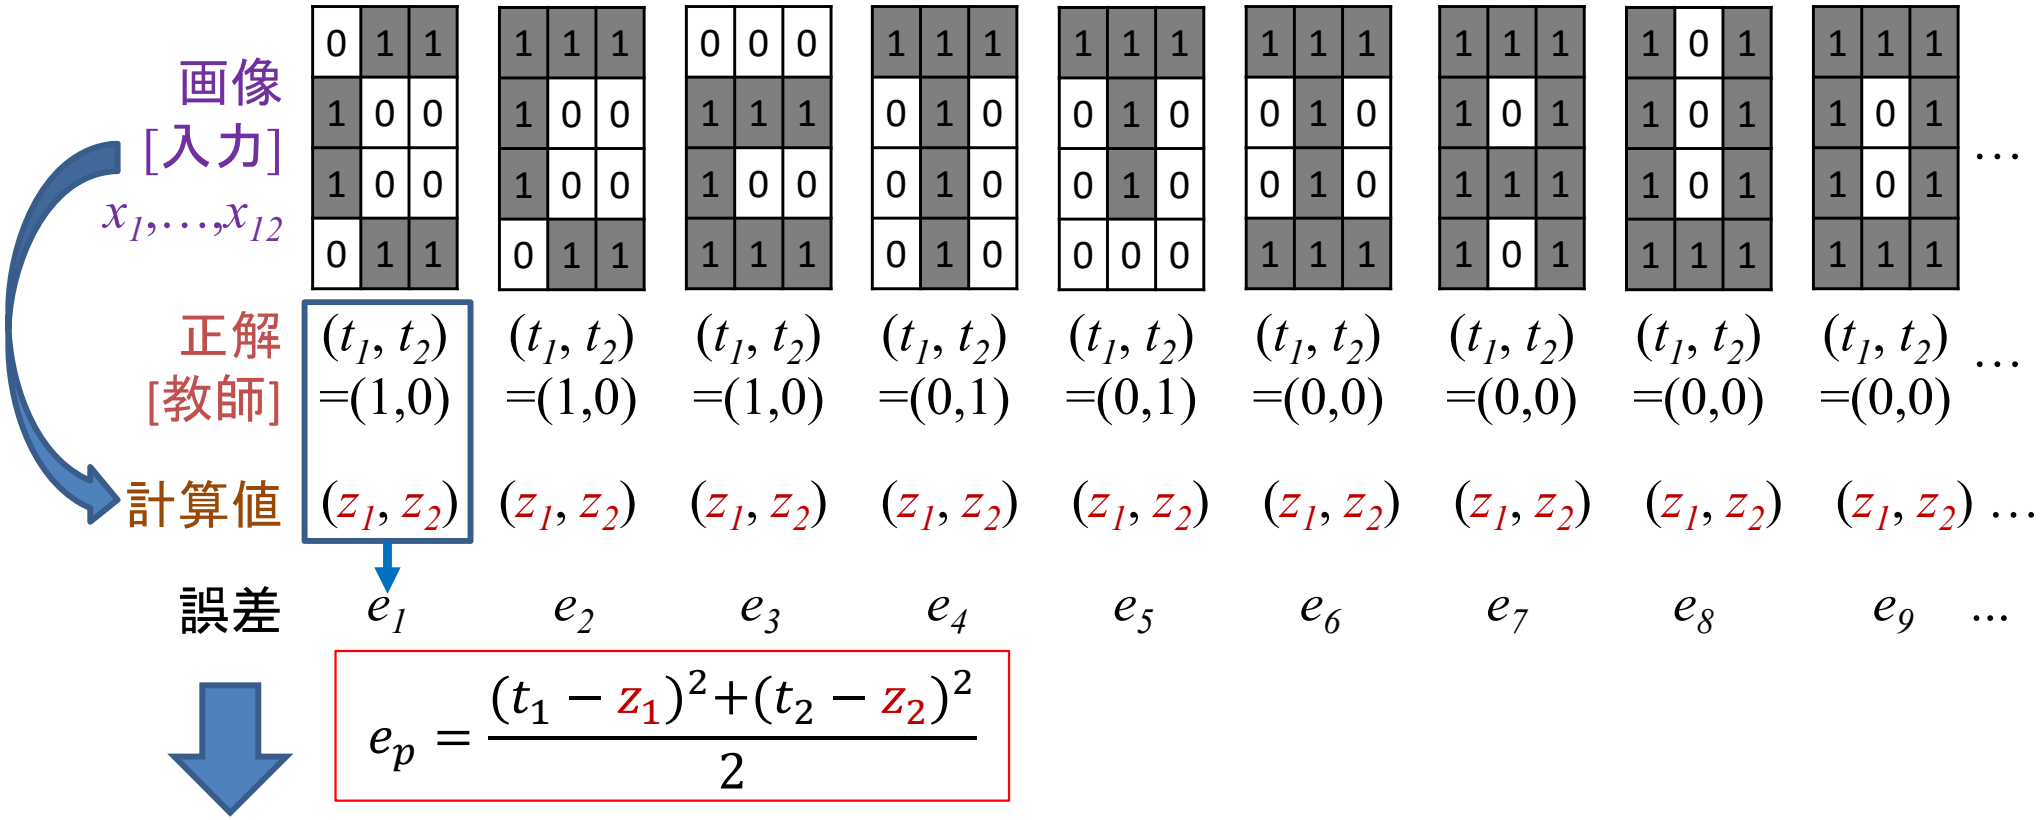

$$e_p = \frac{(t_1 - z_1)^2 + (t_2 - z_2)^2}{2}$$

誤差の総和 $E = e_1 + e_2 + e_3 + e_4 + e_5 + e_6 + e_7 + e_8 + e_9 \ldots$

この誤差（の総和）が最小になるように，ネットワークの各ユニットがもつ固有の値[パラメータ]（ w_i^H $(i = 1,2,3)$, w_j^o $(j = 1,2)$ ）を機械に学習・設定させる

機械学習（誤差の総和最小化）

➢ 誤差総和 E の最小化

$$E = e_1 + e_2 + \dots$$

$$e_p = \frac{(t_1 - z_1)^2 + (t_2 - z_2)^2}{2}$$

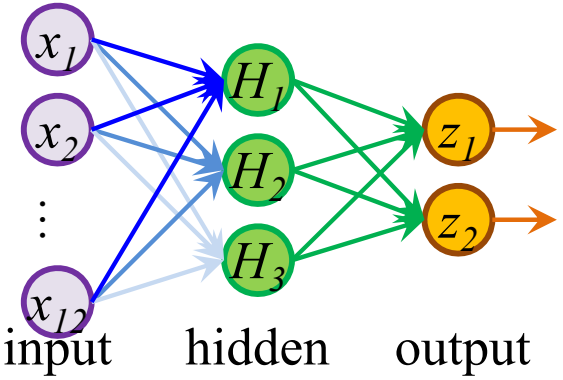

$$\begin{cases} z_1 = a(s_1^o) \\ z_2 = a(s_2^o) \end{cases} \quad \begin{cases} s_1^o = (\boldsymbol{w}_1^o)^T \boldsymbol{h} \\ s_2^o = (\boldsymbol{w}_2^o)^T \boldsymbol{h} \end{cases}$$

ただし，$\boldsymbol{w}_j^o = \begin{pmatrix} w_{1j}^o \\ w_{2j}^o \\ w_{3j}^o \\ \theta_j^o \end{pmatrix}, \boldsymbol{h} = \begin{pmatrix} h_1 \\ h_2 \\ h_3 \\ -1 \end{pmatrix}$

$(j = 1,2)$

$$\begin{cases} h_1 = a(s_1^H) \\ h_2 = a(s_2^H) \\ h_3 = a(s_3^H) \end{cases} \quad \begin{cases} s_1^H = (\boldsymbol{w}_1^H)^T \boldsymbol{x} \\ s_2^H = (\boldsymbol{w}_2^H)^T \boldsymbol{x} \\ s_3^H = (\boldsymbol{w}_3^H)^T \boldsymbol{x} \end{cases}$$

ただし，$\boldsymbol{w}_i^H = \begin{pmatrix} w_{1i}^H \\ w_{2i}^H \\ \vdots \\ w_{12,i}^H \\ \theta_i^H \end{pmatrix}, \boldsymbol{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_{12} \\ -1 \end{pmatrix}$

$(i = 1,2,3)$

E を最小とするパラメータ（変数）$\boldsymbol{w}_j^o (j = 1,2), \boldsymbol{w}_i^H (i = 1,2,3)$ の値を求めたい

変数の数：（入力数+1）×（隠れ層数）+（隠れ層数+1）×（出力数）=13*3+4*2 = 47

解析的に解く（求める）のは困難なので，反復数値計算（勾配法）で求める

機械学習（誤差の総和最小化）

- 反復数値計算（勾配法）
  - 初期解 $\boldsymbol{w}^0$ から最適解 $\boldsymbol{w}^*$ へ
  - 解の更新 $\boldsymbol{w}^{k+1}=\boldsymbol{w}^k+\eta\Delta\boldsymbol{w}^k$ $(k=0,1,2,\ldots)$
    - ✓反復 k 回目の降下方向 $\Delta\boldsymbol{w}^k$ $(k=0,1,2,\ldots)$
    - ✓反復サイズ（step size） η

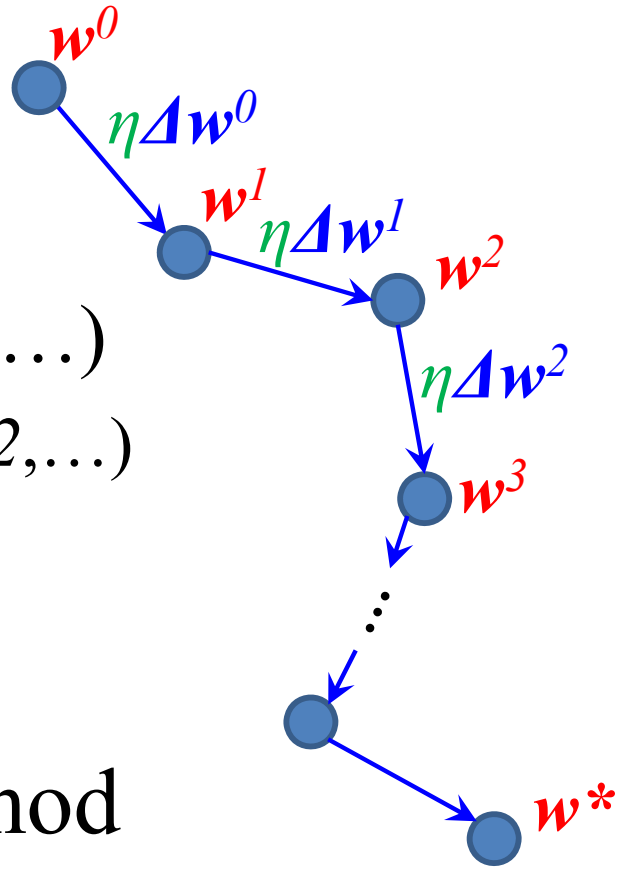

- 最急降下法 steepest descent method
  - 降下方向 $\Delta\boldsymbol{w}$ に最急降下方向を使う手法
  - 関数 $f(\boldsymbol{w})$ の最急降下方向は $-\nabla f(\boldsymbol{w}) = -\begin{pmatrix} \frac{\partial f}{\partial w_1} \\ \vdots \\ \frac{\partial f}{\partial w_n} \end{pmatrix}$

※最急降下法は勾配法の一種で，最も簡便な手法
※勾配法のstep sizeは直線探索（Armijo method等）で求める

機械学習（誤差の総和最小化）

- 例題の解$\boldsymbol{w}$と降下方向$\Delta \boldsymbol{w}$

$$\boldsymbol{w} = \begin{pmatrix} \boldsymbol{w}_1^o \\ \boldsymbol{w}_2^o \\ \boldsymbol{w}_1^H \\ \boldsymbol{w}_2^H \\ \boldsymbol{w}_3^H \end{pmatrix} = \begin{pmatrix} w_{11}^o \\ w_{21}^o \\ w_{31}^o \\ \theta_1^o \\ \vdots \\ w_{13}^H \\ w_{23}^H \\ \vdots \\ w_{12,3}^H \\ \theta_3^H \end{pmatrix} \in R^{47}, \Delta \boldsymbol{w} = \begin{pmatrix} \Delta \boldsymbol{w}_1^o \\ \Delta \boldsymbol{w}_2^o \\ \Delta \boldsymbol{w}_1^H \\ \Delta \boldsymbol{w}_2^H \\ \Delta \boldsymbol{w}_3^H \end{pmatrix} = \begin{pmatrix} \Delta w_{11}^o \\ \Delta w_{21}^o \\ \Delta w_{31}^o \\ \Delta \theta_1^o \\ \vdots \\ \Delta w_{13}^H \\ \Delta w_{23}^H \\ \vdots \\ \Delta w_{12,3}^H \\ \Delta \theta_3^H \end{pmatrix} \in R^{47}$$

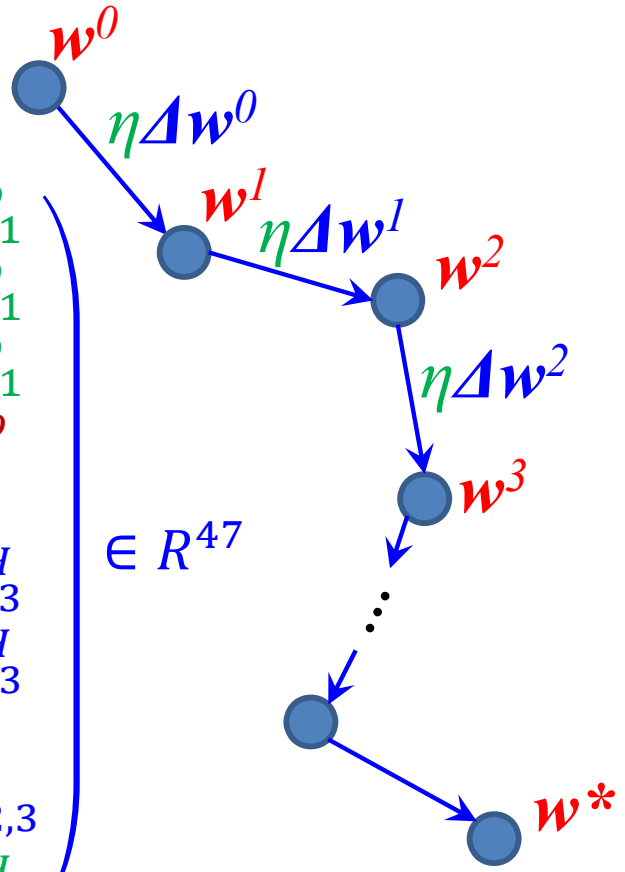

- 例題の誤差総和Eの最急降下方向

$$\Delta \boldsymbol{w} = -\nabla E(\boldsymbol{w}) = -\begin{pmatrix} \vdots \\ \dfrac{\partial E}{\partial w_l} \\ \vdots \end{pmatrix}, \qquad \frac{\partial E}{\partial w_l} = \frac{\partial e_1}{\partial w_l} + \frac{\partial e_2}{\partial w_l} + \cdots$$

機械学習（誤差逆伝播法backpropagation）

➤ 出力層の勾配[(重み3+閾値1)×2=8個]

$$
\begin{cases}
\dfrac{\partial e_p}{\partial w_{11}^o} = \dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial w_{11}^o} = (z_1 - t_1)a'(s_1^o)h_1 \\
\dfrac{\partial e_p}{\partial w_{21}^o} = \dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial w_{21}^o} = (z_1 - t_1)a'(s_1^o)h_2 \\
\dfrac{\partial e_p}{\partial w_{31}^o} = \dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial w_{31}^o} = (z_1 - t_1)a'(s_1^o)h_3 \\
\dfrac{\partial e_p}{\partial \theta_1^o} = \dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial \theta_1^o} = -(z_1 - t_1)a'(s_1^o)
\end{cases}
$$

$$
\begin{cases}
\dfrac{\partial e_p}{\partial w_{12}^o} = \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial w_{12}^o} = (z_2 - t_2)a'(s_2^o)h_1 \\
\dfrac{\partial e_p}{\partial w_{22}^o} = \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial w_{22}^o} = (z_2 - t_2)a'(s_2^o)h_2 \\
\dfrac{\partial e_p}{\partial w_{32}^o} = \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial w_{32}^o} = (z_2 - t_2)a'(s_2^o)h_3 \\
\dfrac{\partial e_p}{\partial \theta_2^o} = \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial \theta_2^o} = -(z_2 - t_2)a'(s_2^o)
\end{cases}
$$

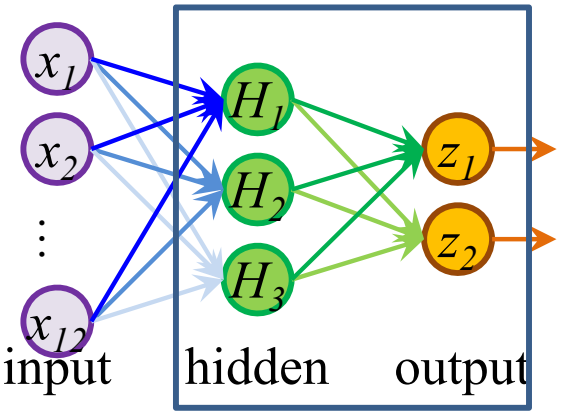

$$e_p = \frac{(t_1 - z_1)^2 + (t_2 - z_2)^2}{2}$$

$$
\begin{cases}
z_1 = a(s_1^o) \\
z_2 = a(s_2^o)
\end{cases}
$$

$$
\rightarrow \begin{cases}
\dfrac{\partial e_p}{\partial z_1} = (z_1 - t_1) \\
\dfrac{\partial e_p}{\partial z_2} = (z_2 - t_2)
\end{cases}
\qquad
\rightarrow \begin{cases}
\dfrac{\partial z_1}{\partial s_1^o} = a'(s_1^o) \\
\dfrac{\partial z_2}{\partial s_2^o} = a'(s_2^o)
\end{cases}
$$

$$
\begin{cases}
s_1^o = w_{11}^o h_1 + w_{21}^o h_2 + w_{31}^o h_3 - \theta_1^o \\
s_2^o = w_{12}^o h_1 + w_{22}^o h_2 + w_{32}^o h_3 - \theta_2^o
\end{cases}
$$

$$
\rightarrow \begin{cases}
\dfrac{\partial s_1^o}{\partial w_{11}^o} = h_1, \dfrac{\partial s_1^o}{\partial w_{21}^o} = h_2, \dfrac{\partial s_1^o}{\partial w_{31}^o} = h_3, \dfrac{\partial s_1^o}{\partial \theta_1^o} = -1 \\
\dfrac{\partial s_2^o}{\partial w_{12}^o} = h_1, \dfrac{\partial s_2^o}{\partial w_{22}^o} = h_2, \dfrac{\partial s_2^o}{\partial w_{32}^o} = h_3, \dfrac{\partial s_2^o}{\partial \theta_2^o} = -1
\end{cases}
$$

機械学習（誤差逆伝播法backpropagation）

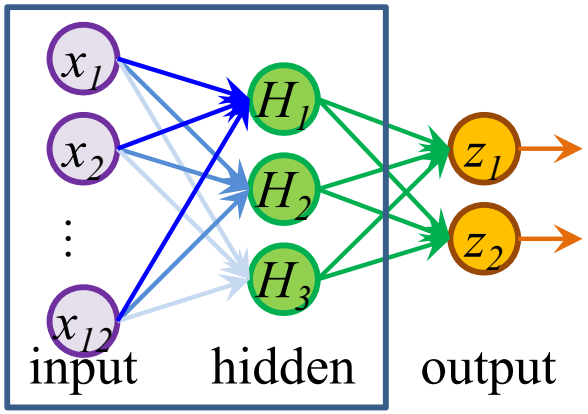

➢ 隠れ層の勾配[(重み12+閾値1)×3=39個]

✓ $i=1(H_1), 2(H_2), 3(H_3)$の場合の各13個

$$\begin{cases} \dfrac{\partial e_p}{\partial w_{1i}^H} = \left(\dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial h_i} + \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial h_i}\right)\dfrac{\partial h_i}{\partial s_i^H}\dfrac{\partial s_i^H}{\partial w_{1i}^H} \\ \quad = \left((z_1-t_1)a'(s_1^o)w_{i1}^o + (z_2-t_2)a'(s_2^o)w_{i2}^o\right)a'(s_i^H)x_1 \\ \quad\quad \vdots \\ \dfrac{\partial e_p}{\partial w_{12,i}^H} = \left(\dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial h_i} + \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial h_i}\right)\dfrac{\partial h_i}{\partial s_i^H}\dfrac{\partial s_i^H}{\partial w_{12,i}^H} \\ \quad = \left((z_1-t_1)a'(s_1^o)w_{i1}^o + (z_2-t_2)a'(s_2^o)w_{i2}^o\right)a'(s_i^H)x_{12} \\ \dfrac{\partial e_p}{\partial \theta_i^H} = \left(\dfrac{\partial e_p}{\partial z_1}\dfrac{\partial z_1}{\partial s_1^o}\dfrac{\partial s_1^o}{\partial h_i} + \dfrac{\partial e_p}{\partial z_2}\dfrac{\partial z_2}{\partial s_2^o}\dfrac{\partial s_2^o}{\partial h_i}\right)\dfrac{\partial h_i}{\partial s_i^H}\dfrac{\partial s_i^H}{\partial \theta_i^H} \\ \quad = -\left((z_1-t_1)a'(s_1^o)w_{i1}^o + (z_2-t_2)a'(s_2^o)w_{i2}^o\right)a'(s_i^H) \end{cases} \quad (i=1,2,3)$$

$$\begin{cases} h_1 = a(s_1^H) \\ h_2 = a(s_2^H) \\ h_3 = a(s_3^H) \end{cases}$$

$$\begin{cases} s_1^H = w_{11}^H x_1 + \cdots + w_{12,1}^H x_{12} - \theta_1^H \\ s_2^H = w_{12}^H x_1 + \cdots + w_{12,2}^H x_{12} - \theta_2^H \\ s_3^H = w_{13}^H x_1 + \cdots + w_{12,3}^H x_{12} - \theta_3^H \end{cases} \rightarrow \begin{cases} \dfrac{\partial s_1^H}{\partial w_{11}^H} = x_1, \cdots, \dfrac{\partial s_1^H}{\partial w_{12,1}^H} = x_{12}, \dfrac{\partial s_1^H}{\partial \theta_1^H} = -1 \\ \dfrac{\partial s_2^H}{\partial w_{12}^H} = x_1, \cdots, \dfrac{\partial s_2^H}{\partial w_{12,2}^H} = x_{12}, \dfrac{\partial s_2^H}{\partial \theta_2^H} = -1 \\ \dfrac{\partial s_3^H}{\partial w_{13}^H} = x_1, \cdots, \dfrac{\partial s_3^H}{\partial w_{12,3}^H} = x_{12}, \dfrac{\partial s_3^H}{\partial \theta_3^H} = -1 \end{cases} \rightarrow \begin{cases} \dfrac{\partial h_1}{\partial s_1^H} = a'(s_1^H) \\ \dfrac{\partial h_2}{\partial s_2^H} = a'(s_2^H) \\ \dfrac{\partial h_3}{\partial s_3^H} = a'(s_3^H) \end{cases}$$

機械学習（誤差逆伝播法backpropagation）

- 活性化関数 $a(s)$ の微分 $a'(s)$
  - シグモイド関数 sigmoid function

$$\sigma(s) = \frac{1}{1+e^{-s}}$$

$$\frac{\partial \sigma}{\partial s} = -\frac{-e^{-s}}{(1+e^{-s})^2} = \frac{1+e^{-s}-1}{(1+e^{-s})^2}$$
$$= \frac{1}{1+e^{-s}} \cdot \left(1 - \frac{1}{1+e^{-s}}\right)$$
$$= \sigma(s)\{1-\sigma(s)\}$$

  - 双曲線正接関数 hyperbolic tangent function

$$tanh(s) = \frac{e^{s}-e^{-s}}{e^{s}+e^{-s}}$$

$$\frac{\partial t}{\partial s} = \frac{(e^{s}+e^{-s})^2 - (e^{s}-e^{-s})^2}{(e^{s}+e^{-s})^2}$$
$$= 1 - tanh(s)^2$$

  - ランプ関数 ReLU ramp function

$$ReLU(s) = \begin{cases} s & (s \geq 0) \\ 0 & (s < 0) \end{cases}$$

$$\frac{\partial R}{\partial s} = \begin{cases} 1 & (s > 0) \\ 0 & (s < 0) \end{cases}$$

※s=0で微分不可能 indifferentiable
※凸関数より s=0で劣微分可能 subdifferentiable

  - etc.

機械学習（教師あり学習）

- 機械学習のアルゴリズム algorithm

1. 入力と正解の組を充分数準備．初期解 $\boldsymbol{w}^0$ を生成（=各ユニット固有の値の初期値を設定）．$k = 0$
2. 入力（$x_1,\ldots,x_{12}$）から，各ユニット固有の値 $\boldsymbol{w}^k$ で出力（z_1, z_2）を計算（※準備した全てについて計算）
3. 正解（t_1, t_2）と出力（z_1, z_2）から誤差 E を計算（※準備した全てについて計算し，誤差e_pの和 E を計算）
4. 誤差 E が十分小さい（$E < \varepsilon$）なら終了．そうでなければ，誤差逆伝播法で勾配 $\Delta \boldsymbol{w}^k$ を計算
5. 勾配法（最急降下法）で解を更新 $\boldsymbol{w}^{k+1} = \boldsymbol{w}^k + \eta \Delta \boldsymbol{w}^k$．$k = k+1$ として step 2へ

機械学習（教師あり学習）

※[2]斎藤康毅「ゼロから作るDeep Learning」オライリージャパン（2016）6章 学習に関するテクニック

➢ 補足

- ✓ ネットワークの構成
  - 層の数をどうするか？ / 各層のノード数をどうするか？
- ✓ 初期解 w^0 の生成（重要）
  - Xavierの初期値（sigmoid関数/tanh関数）
  - Heの初期値（ReLU関数）
- ✓ 勾配法の選択と step size の決め方
  - 最急降下法 steepest descent method
  - Momentum
  - AdaGrad; adaptive gradient
  - Adam
- ✓ 過学習 overfitting への対処
  - Weight Decay
  - Dropout

参考文献

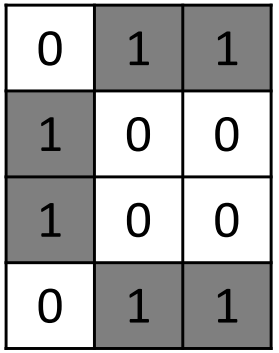

[1]涌井良幸・涌井貞美「Excelでわかる機械学習超入門」
技術評論社（2019）

[2]斎藤康毅「ゼロから作るDeep Learning」
オライリージャパン（2016）