

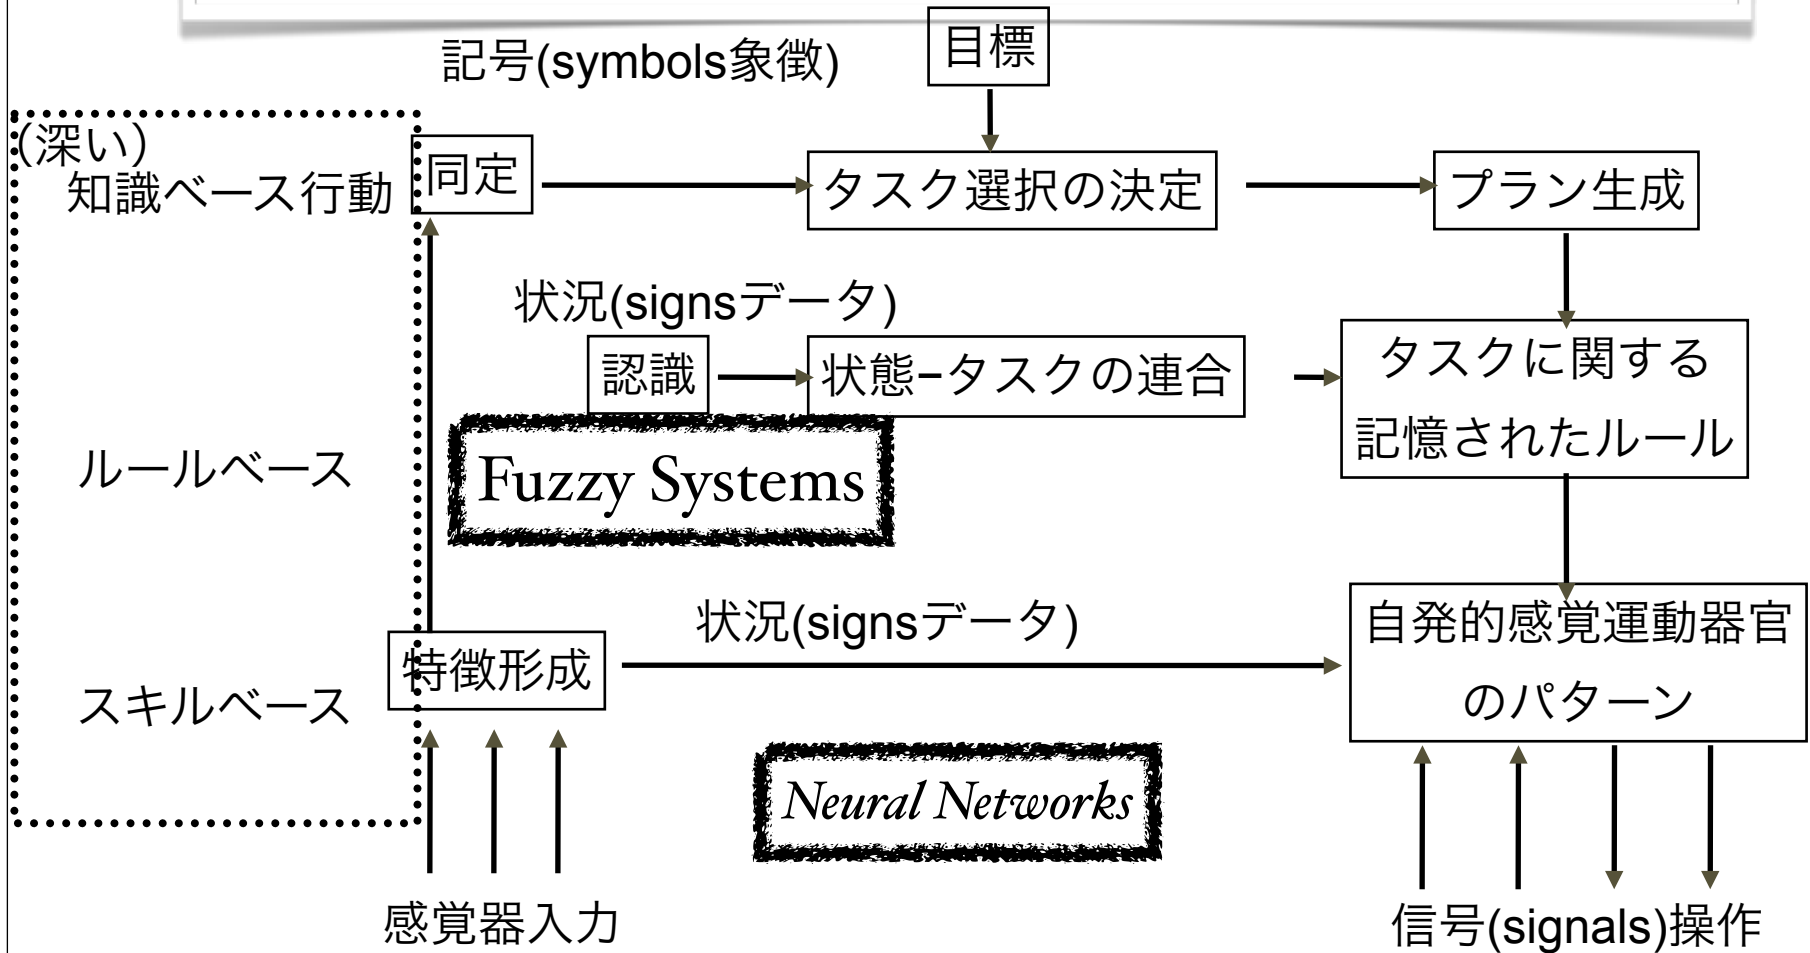
情報メディア論2

2010-8

ニューラルネットワークモデル
一階層型ニューラルネットワーク

人間の行動様式分析

Rusmussen 1980



Fuzzy + Neural Network

Fuzzy Systems

→ (言語的)ルールで記述

Neural Networks

→ 信号処理

学習

?

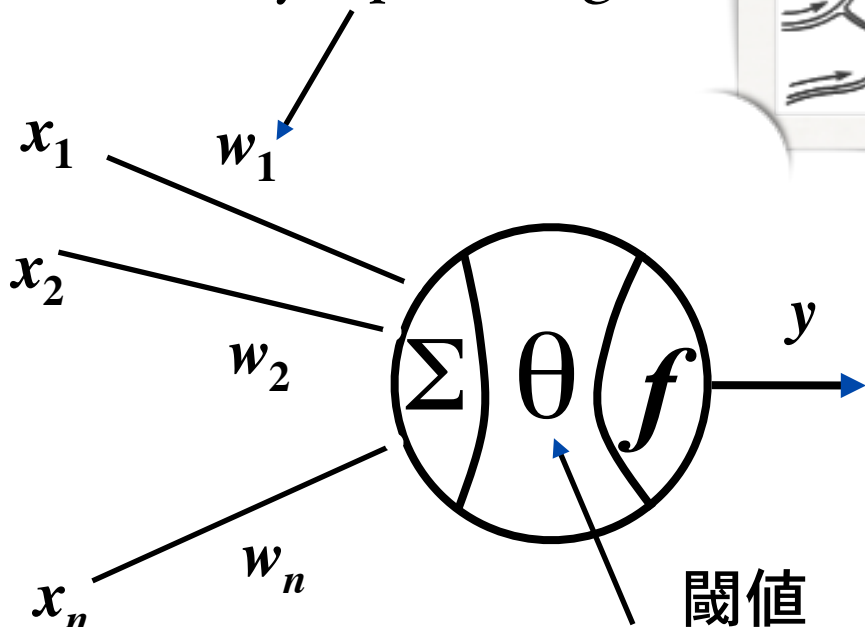

信号処理 → ルール化

記号処理 → 信号処理

ニューロンモデル

- McCulloch, Pitts (1943)

シナプス荷重(synaptic weight)



2値出力の例

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

入出力関係

$$y = f\left(\sum w_i x_i - \theta\right) \quad (\text{Threshold})$$

入力が θ を超えると出力 (発火)


w_i を適切に変更する

||

学習

ニューロンモデル

$$\theta \longrightarrow w_0$$



簡略化


- ・プログラムの容易さ
- ・閾値の学習

入出力関係

$$y = f\left(\sum w_i x_i - \theta\right)$$

パーセプトロン(識別機械)

- Rosenblatt (1961)




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

x1	x2	x3	...	y^*
0.2	23	4.5	...	○
5.0	3.3	2.2	...	×
...
				○
				×
				×

パーセプトロン(2)

$$y = f\left(\sum w_i x_i - w_0\right)$$

$$y = w_1 x_1 + w_2 x_2 + \cdots + w_n x_n - w_0$$

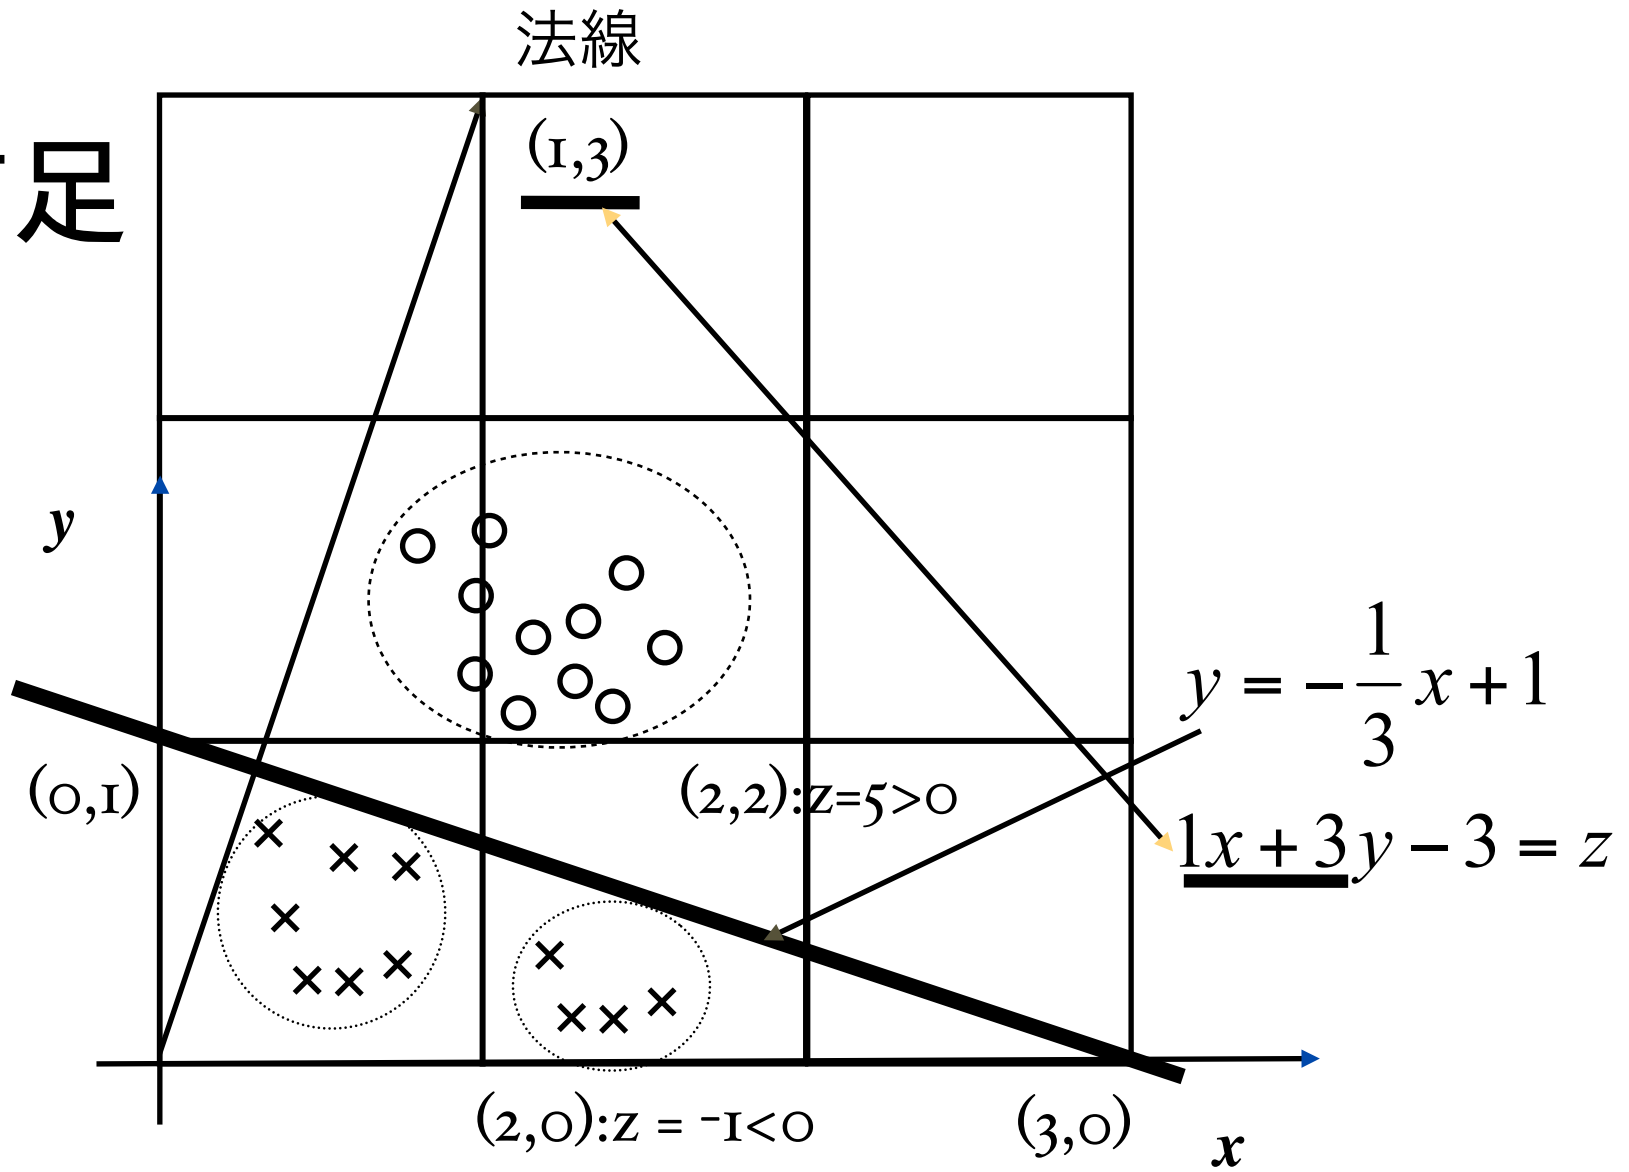


ニューロンが表す (超) 平面
が
カテゴリ分離平面になるよう
に

学習

w_i の調整

補足



パーセプトロン学習則

シナプス荷重ベクトル

$X =$

x1	x2	x3	...	y^*
x11	x12	x13	...	y^{*1}
x21	x22	x23	...	y^{*2}
...
			xnn	

$$W = \{w_1, w_2, \dots, w_n\}$$

$$y = X \cdot W^T$$

$$y = \begin{cases} 1 & (X \cdot W^T > 0) \\ 0 & (X \cdot W^T \leq 0) \end{cases}$$

荷重ベクトルの更新：学習

$$\Delta W^T = -\varepsilon \underbrace{(y - y^*)}_{\text{誤差}} X$$

$0 < \varepsilon \ll 1$: (学習係数)

誤差

$$W(t+1) = W(t) + \Delta W \quad \text{により更新}$$

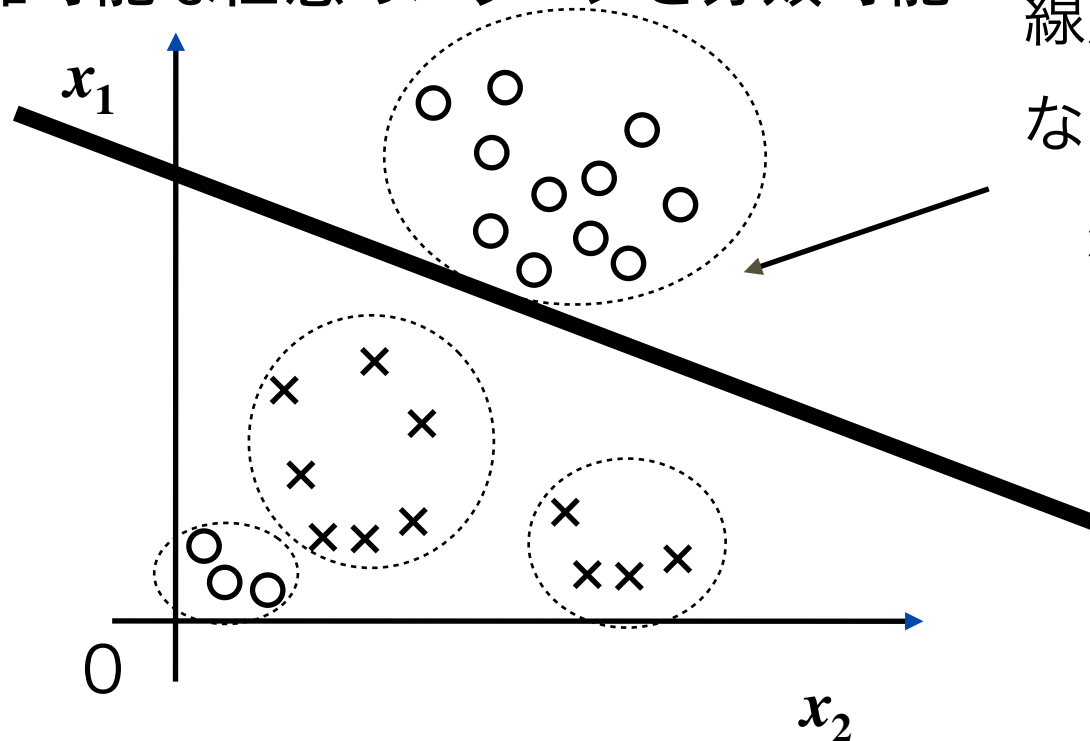
学習則 $W(t+1) = W(t) + \Delta W$

収束定理：有限回の学習で正しい識別をする

パーセプトロンの限界

線形分離可能な任意のパターンを分類可能

線形分離不可能
なデータには対
処できない




線形分離不可能な問題

- ニューロンを多数つなげる
 - 非線形関数 f

f :(微分可能な)非線形関数

階層型ニューラルネットワーク

入力層 中間層 (隠れ層) 出力層





所望の入出力パターン対

$$\min E = \frac{1}{2} \sum (y_p - y_p^*)^2$$

階層型NNの学習則


$$\min E = \frac{1}{2} \sum (y_i - y_i^*)^2$$



$$\Delta w_{ji} = -\varepsilon \frac{\partial E}{\partial w_{ji}}$$

$$\varepsilon > 0$$

学習則の導出の前に



$$u_j = \sum_i w_{ji} y_i$$


$$y_j = f(u_j)$$

$$f(u_j) = \frac{1}{1 + e^{-u_j}}$$

↑
シグモイド関数

シグモイド関数

$$f(x) = \frac{I}{1 + \exp(-x)}$$



- 閾値（特性）関数
- ロジスティック方程式の一般解の一つ

$$\frac{dx}{dt} = x(I - x)$$

学習則

$$\min E = \frac{1}{2} \sum (y_i - y_i^*)^2$$

$$u_j = \sum_i w_{ji} y_i$$
$$y_j = f(u_j)$$
$$f(u_j) = \frac{1}{1 + e^{-u_j}}$$


Chain rule

$$\frac{\partial E}{\partial w_{ji}} = \sum \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial u_j} \frac{\partial u_j}{\partial w_{ji}}$$

$$\frac{\partial y_j}{\partial u_j} = f'(u_j) = \underline{y_j(1 - y_j)}$$

$$\frac{\partial u_j}{\partial w_{ji}} = y_i$$

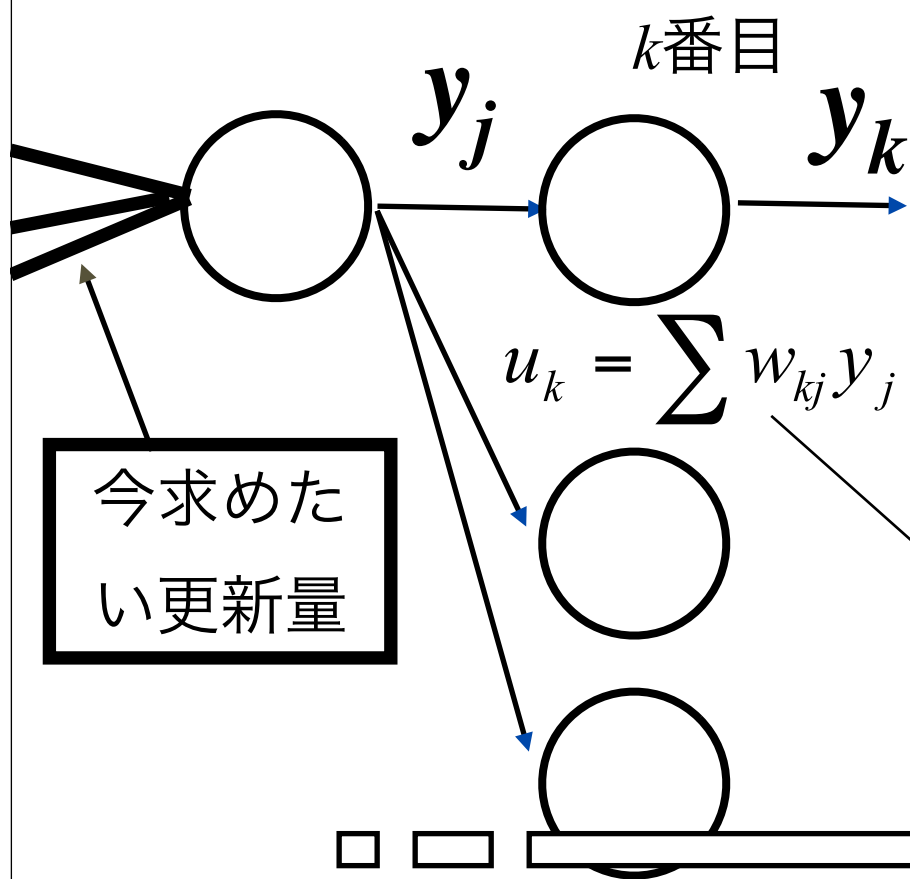
シグモイド関数の場合
(ロジスティック写像)



逆誤差伝播法 Backpropagation

$$\frac{\partial E}{\partial w_{ji}} = \sum \boxed{\frac{\partial E}{\partial y_j}} y_j (1 - y_j) y_i$$

j 番目のニューロン



$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \begin{array}{|c|} \hline \frac{\partial y_k}{\partial u_k} \\ \hline \frac{\partial u_k}{\partial y_j} \\ \hline \end{array}$$

$$\frac{\partial y_k}{\partial u_k} = f'(u_k) = y_k (1 - y_k)$$


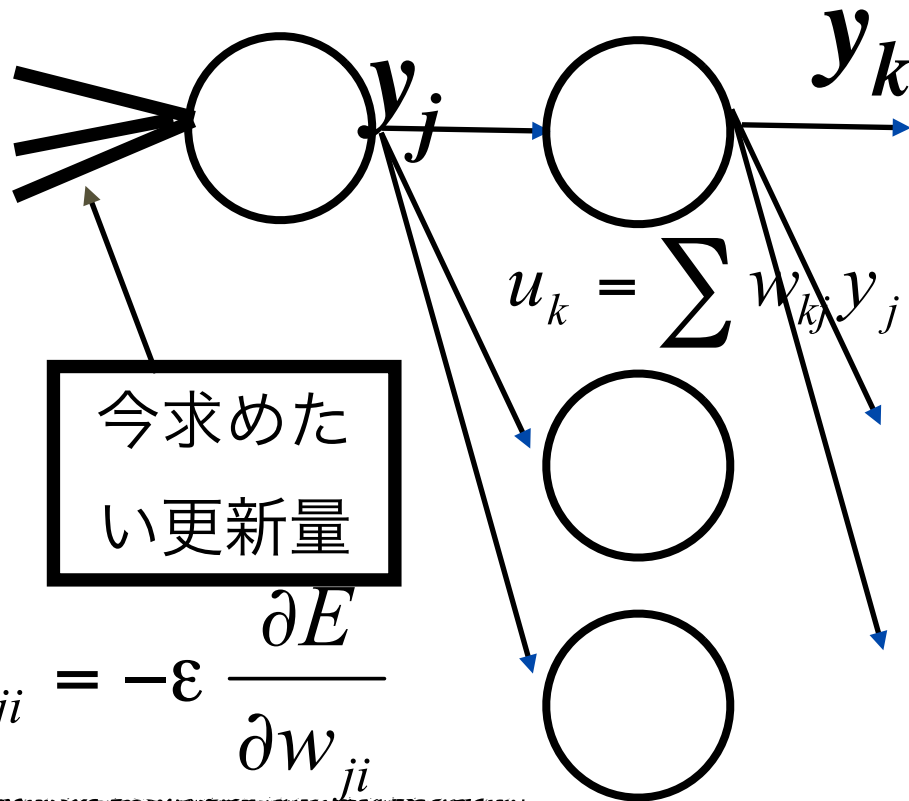
$$\frac{\partial u_k}{\partial y_j} = w_{kj}$$

Backpropagationまとめ

j 番目のニューロン

k 番目

出力層



$$E = \frac{1}{2} \sum (y_p - y_p^*)^2$$

$$\frac{\partial E}{\partial y_p} = (y_p - y_p^*)$$


今求めたい更新量

$$\Delta w_{ji} = -\varepsilon \frac{\partial E}{\partial w_{ji}}$$

具体的に数値計算可能

出力 y

最急降下方向への学習



$$\Delta w_{ji} = -\varepsilon \frac{\partial E}{\partial w_{ji}}$$

Reference

1. McCulloch, W.S., Pitts, W., "A logical calculus of the ideas immanent in nervous activity," Bull. Math. Biophysics, 5, 115-133, 1943
2. Rosenblatt, F., "Principles of Neurodynamics", Spartan, 1961
3. Rumelhart, D.E., Hinton, G.E., Williams, R.J., "Learning representations by back-propagating errors", Nature, 323, 533-536, 1986
4. Rumelhart, D. E. McClelland, J.L. and the PDP Research Group, "Parallel Distributed Learning," MIT Press, 1986
5. 中野他,「ニューロコンピュータの基礎」,コロナ社,1990
6. 甘利,坂田編,「脳とニューラルネット」,朝倉書店,1994
7. 萩原,「ニューロ・ファジィ・遺伝的アルゴリズム」,産業図書,1994
8. 谷萩編,「ニューラルネットワークとファジィ情報処理」,コロナ社,1998