

情報メディア論 2

2010-9



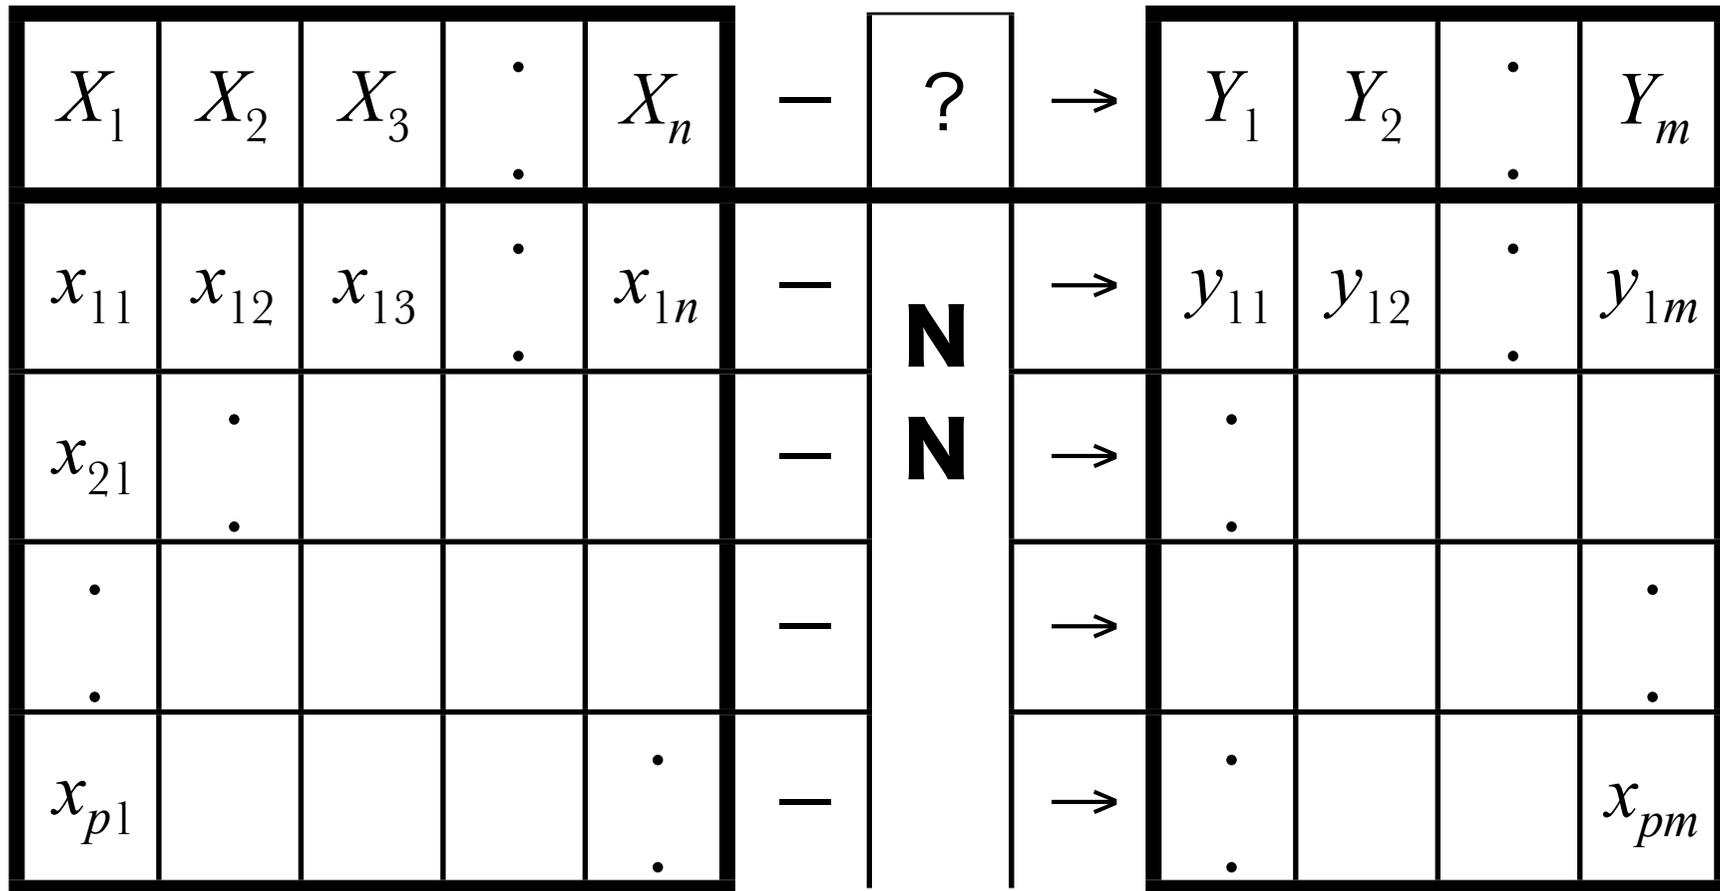
ニューラルネットワーク
いろいろ

ニューラルネットワーク いろいろ

- ❖ 階層型ニューラルネットワーク (BP学習)
 - ❖ 任意の非線形写像のモデリング
 - Fuzzyシステムとの融合
- ❖ 相互結合型ニューラルネットワーク
 - ❖ 連想記憶

所望の入出力パターン対

❖ 任意の非線形写像のモデリング



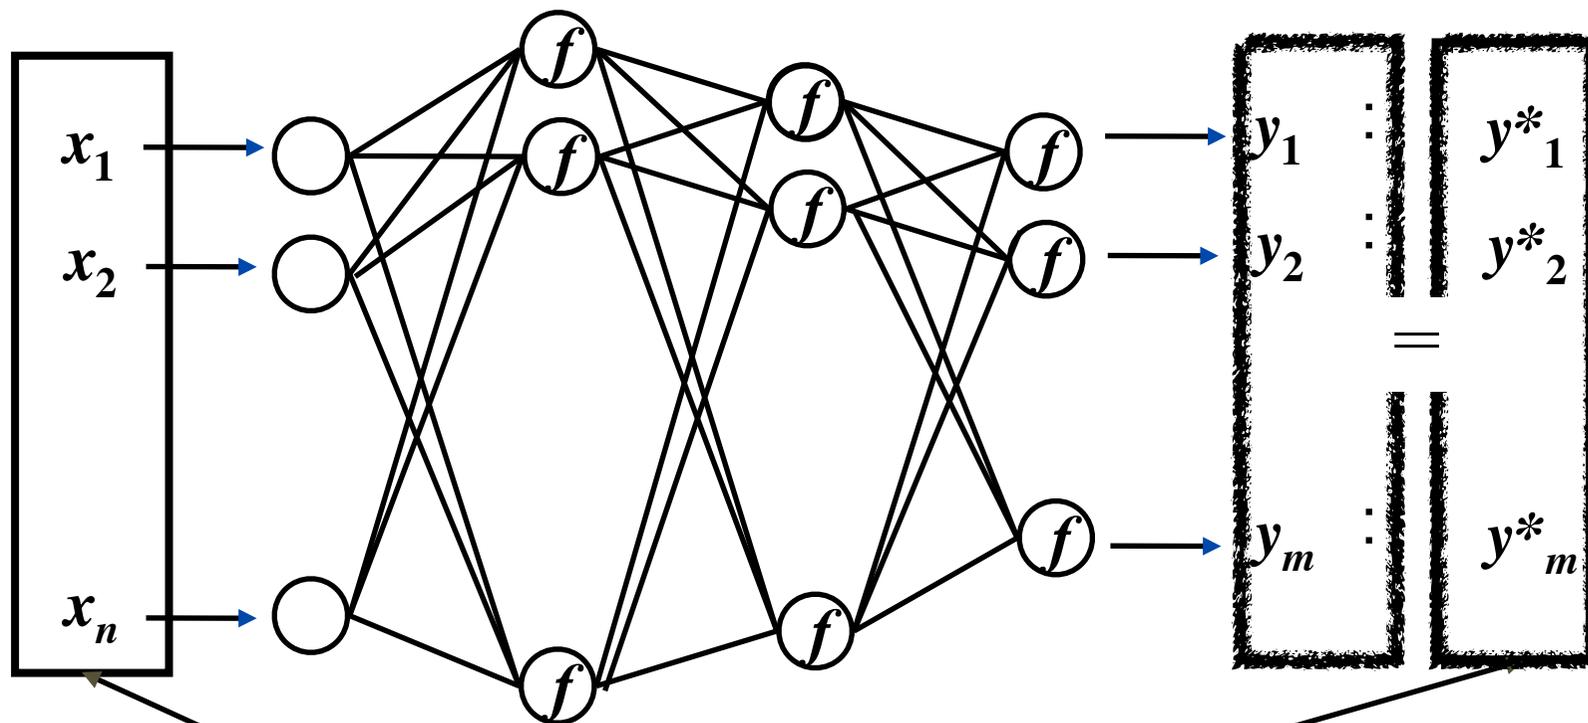
n, m 変数 : p 個のデータ対

先週分

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

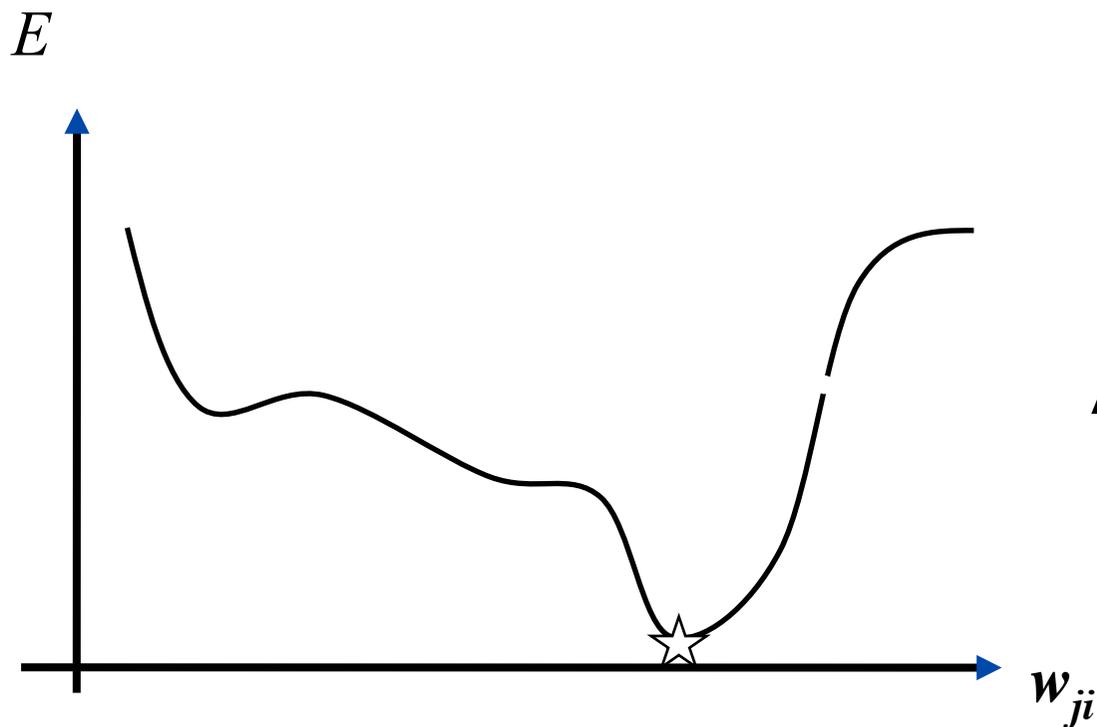


所望の入出力パターン対

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

先週分

最急降下方向への学習



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

x_{11}	x_{12}	x_{13}	\cdot	x_{1n}
----------	----------	----------	---------	----------



y_{11}	y_{12}	\cdot	y_{1m}
----------	----------	---------	----------

x^+_{11}	x^+_{12}	x^+_{13}	\cdot	x^+_{1n}
------------	------------	------------	---------	------------

y^*_{11}	y^*_{12}	\cdot	y^*_{1m}
------------	------------	---------	------------

BPアルゴリズム

技

$$\begin{aligned}\frac{d}{dx} \left(\frac{1}{1 + e^{-x}} \right) &= \frac{d}{dx} (1 + e^{-x})^{-1} \\ &= -1 \cdot (1 + e^{-x})^{-2} \cdot (-e^{-x}) \\ &= \frac{1 + e^{-x} - 1}{(1 + e^{-x})^2} \\ &= \frac{1}{1 + e^{-x}} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{1 + e^{-x}} \left(1 - \frac{1}{1 + e^{-x}} \right) \\ &= y(1 - y)\end{aligned}$$

BPアルゴリズム

$$y = \tanh(x)$$

$$\frac{d}{dx} \tanh(x) = \frac{\sinh(x)}{\cosh(x)}$$

$$= \frac{d}{dx} \left(\frac{(e^x - e^{-x})/2}{(e^x + e^{-x})/2} \right)$$

$$= \frac{d}{dx} \left(\frac{e^x - e^{-x}}{e^x + e^{-x}} \right)$$

$$= -1 \cdot \frac{e^x - e^{-x}}{(e^x + e^{-x})^2} \cdot (e^x - e^{-x}) + \frac{1}{e^x + e^{-x}} \cdot (e^x + e^{-x})$$

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

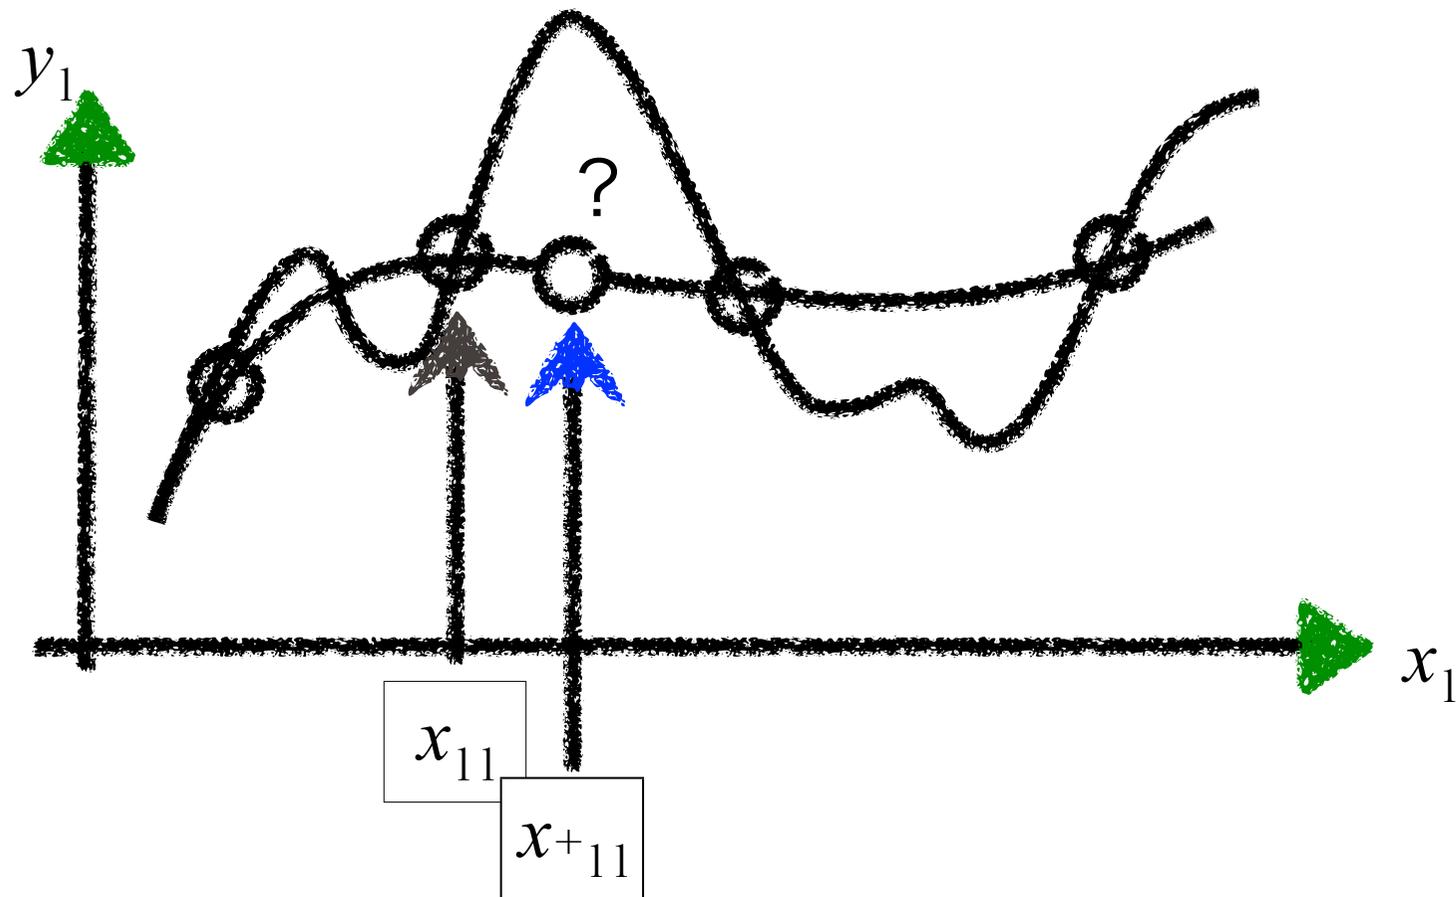
$$= 1 - \tanh^2(x)$$

$$= 1 - y^2$$

$$\frac{dy}{dx} = \frac{1}{\cosh^2(x)}$$

では、yが使えない

❖ 任意の非線形写像のモデリング→近似



ハイブリッドシステム

相補的な組合せ（ごく一例）

- ・ニューラルネットワーク：

学習結果がネットワーク内の結合荷重に分散して記憶される。

→ 中身が良くわからない。

→ ファジィルールを持つニューラルネットワーク

- ・ファジィ：

言語的に表現できないルールをどのように獲得するか？

→ ファジィルールをGAにより探索

- ❖ **Fuzzy Theory**

➡ 言語的記述能力

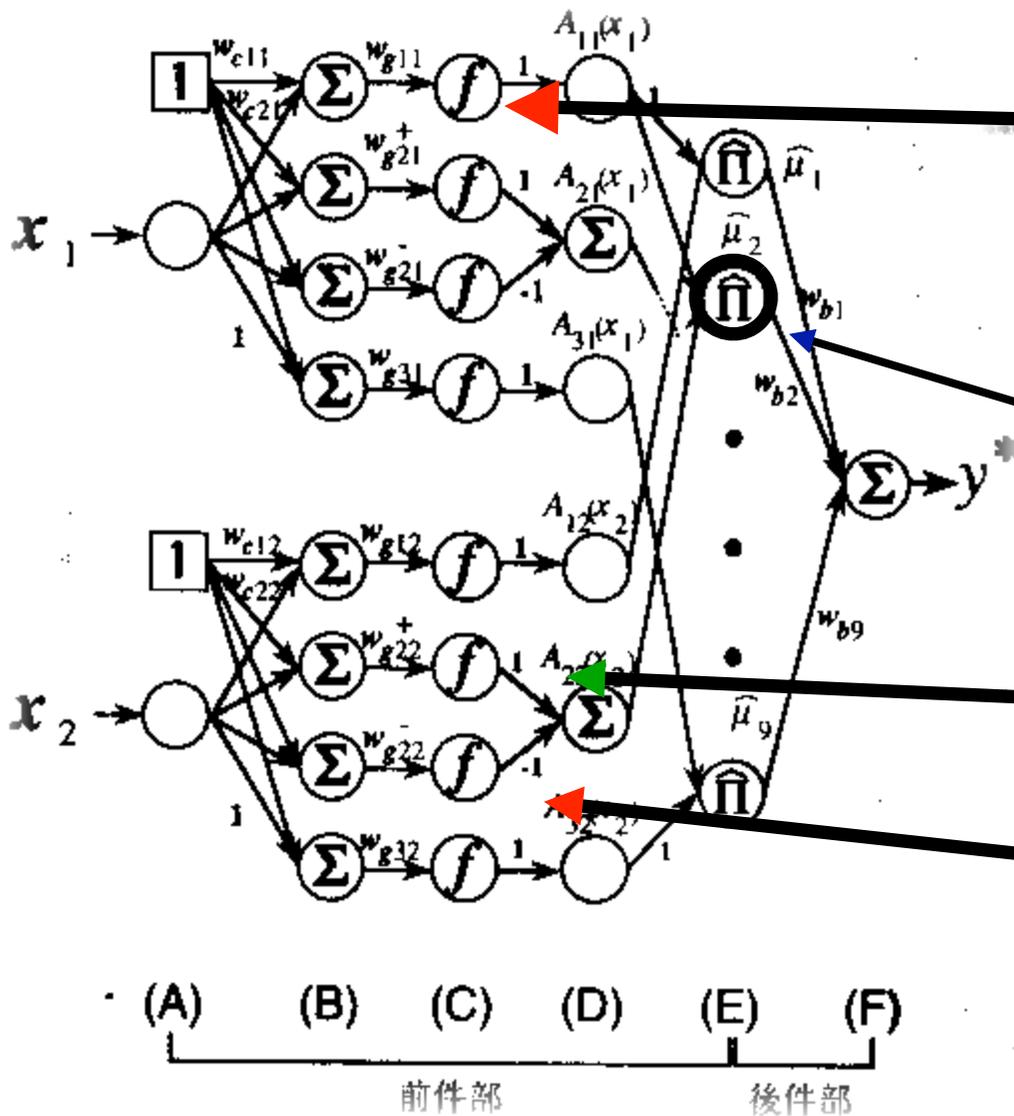
- ❖ **Neural Networks**

➡ 学習能力

- ❖ **Genetic Algorithms**

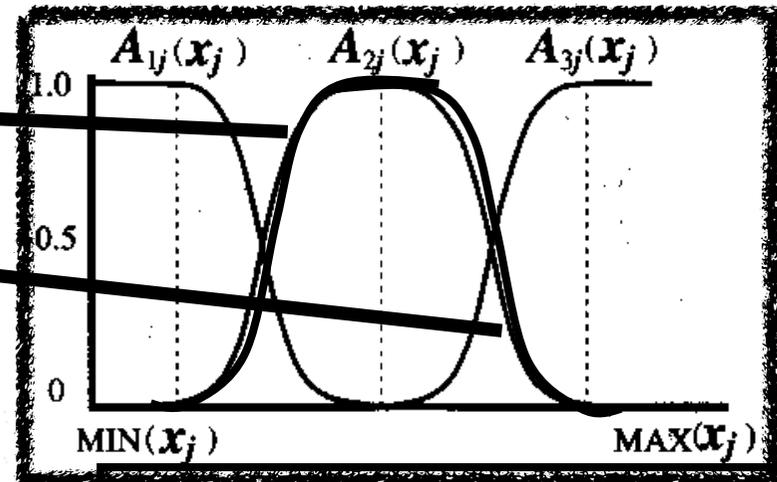
ファジィニューラルネット

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



シグモイド関数

ルールの適合度

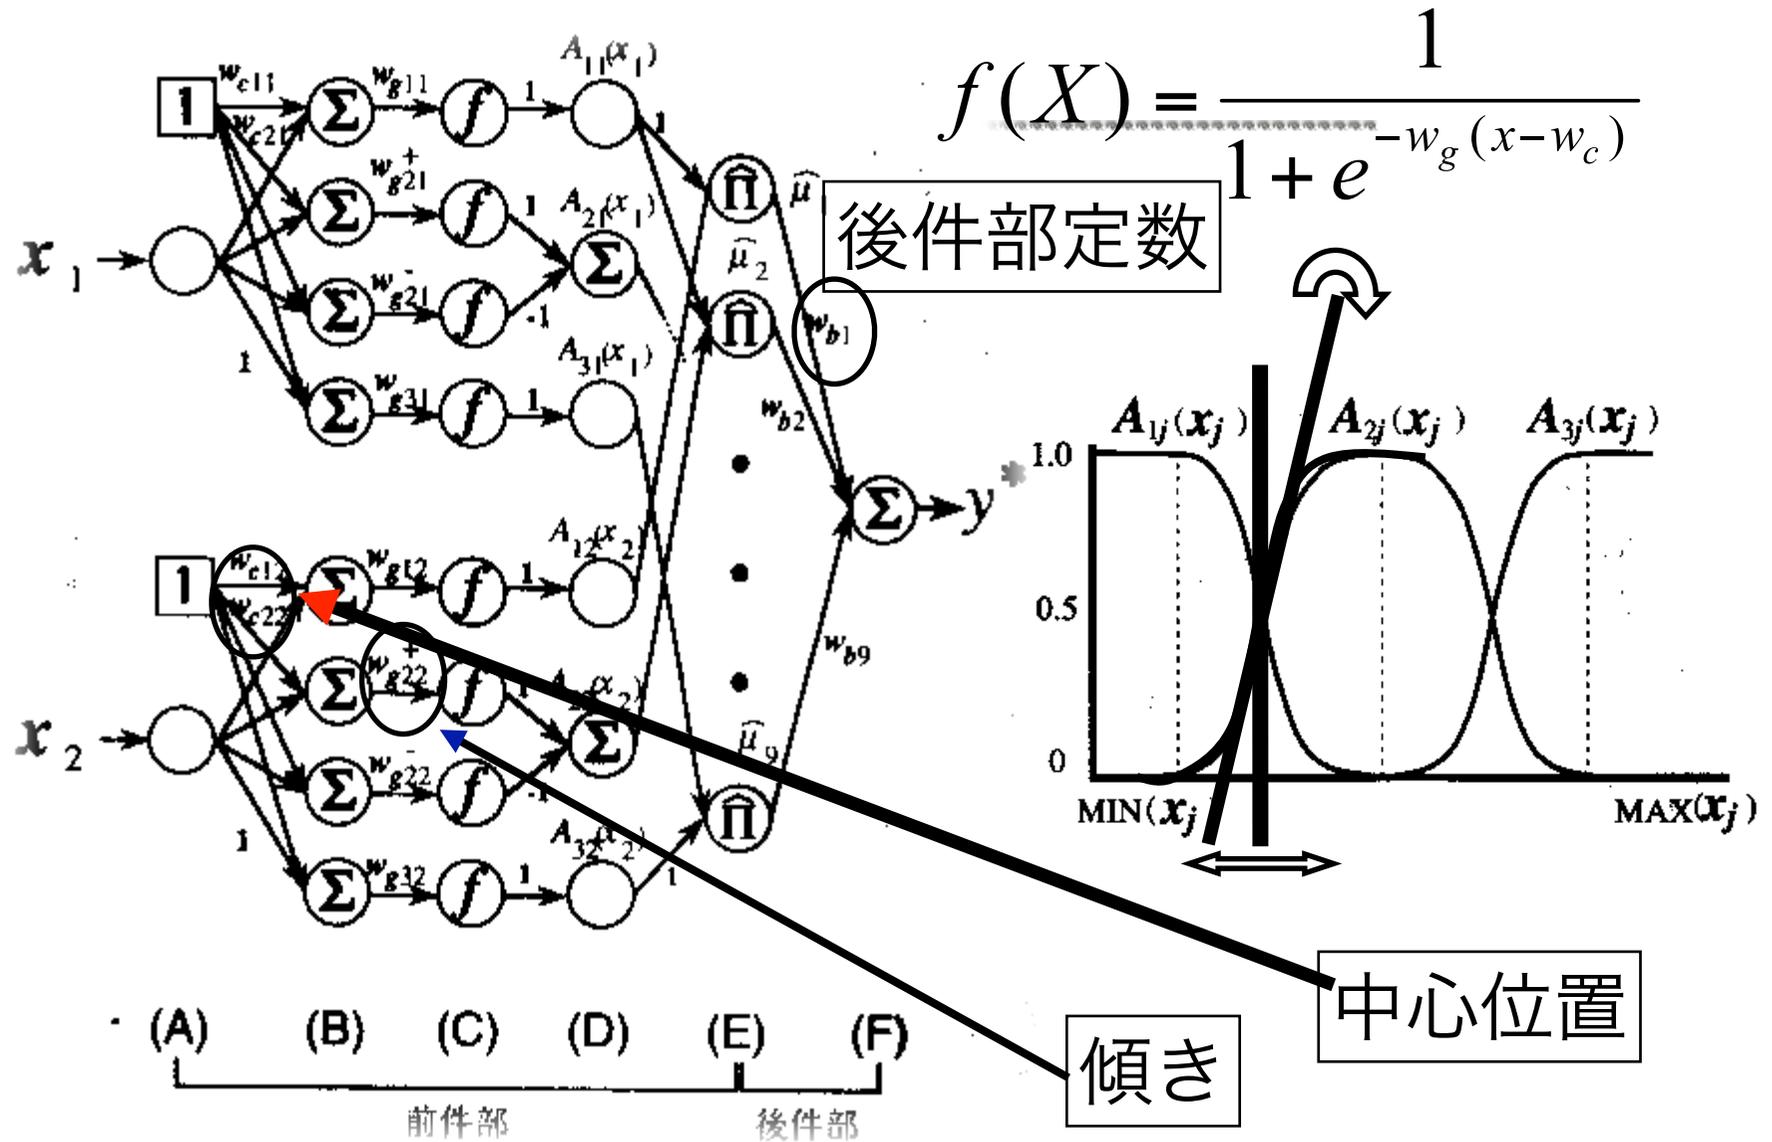


メンバーシップ関数

ファジィ推論を行うニューラルネットワーク

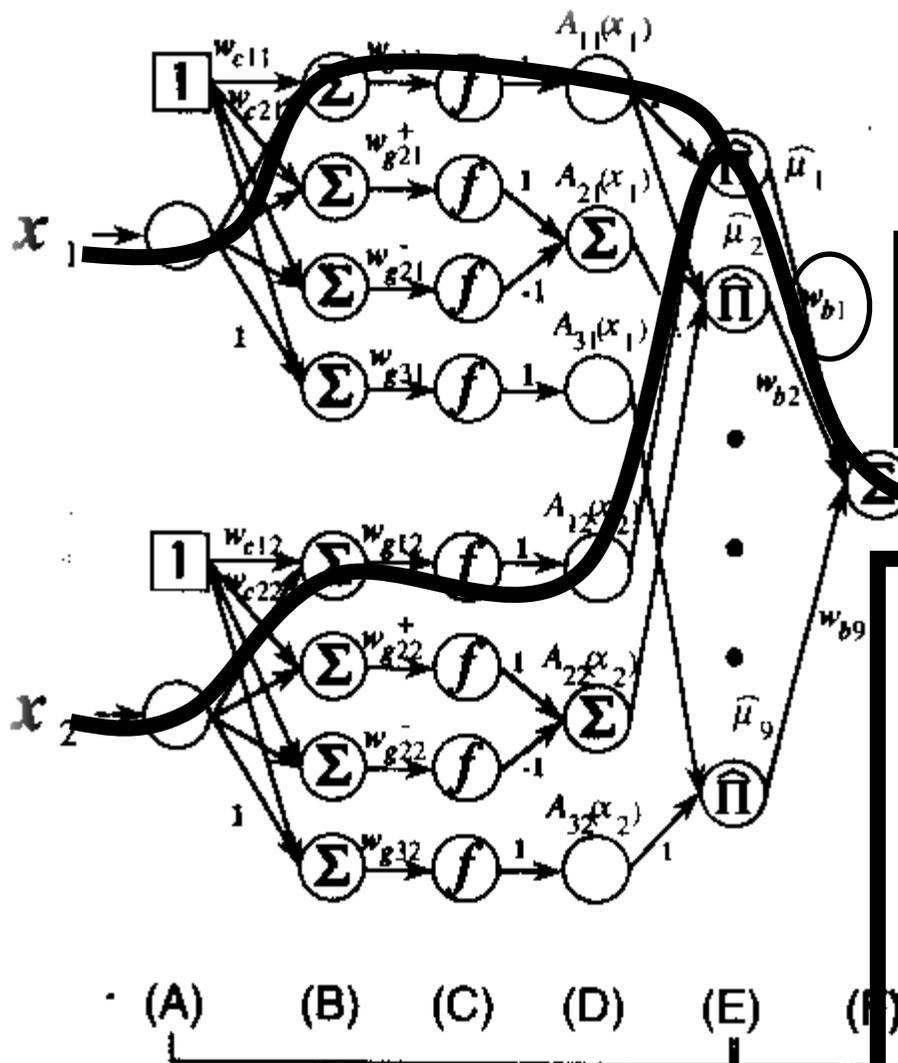


ファジィニューラルネットワーク



ファジィ推論を行うニューラルネットワーク

ファジィニューラルネットワーク



後件部定数

If x_1 is A_{11} and x_2 is A_{12} then

BP学習により、

- ・ 後件部定数 = ルール
- ・ メンバーシップ関数の形状

ファジィ推論を行うニューラルネットワークを決定できる。

ニューラルネットワーク いろいろ

- ❖ 階層型ニューラルネットワーク (BP学習)
 - ❖ 任意の非線形写像のモデリング
 - Fuzzyシステムとの融合
- ❖ 相互結合型ニューラルネットワーク
 - ❖ 連想記憶
 - ❖ 自己組織化特徴マップ
 - ❖ 学習ベクトル量子化

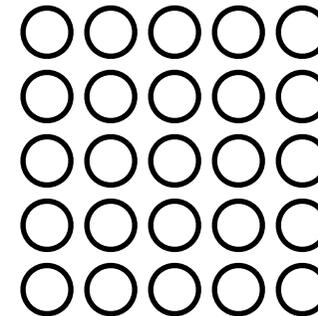
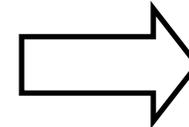
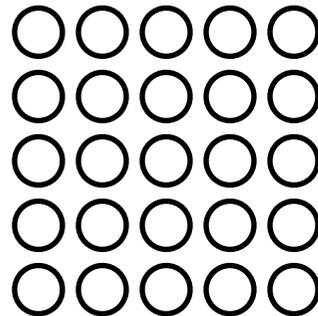
❖ 相互結合型ニューラルネットワーク

アソシアトロン：中野(1972)

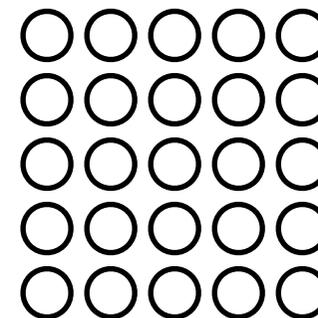
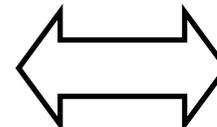
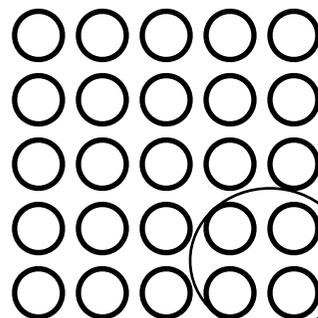
ホップフィールドネット(1982)

連想記憶

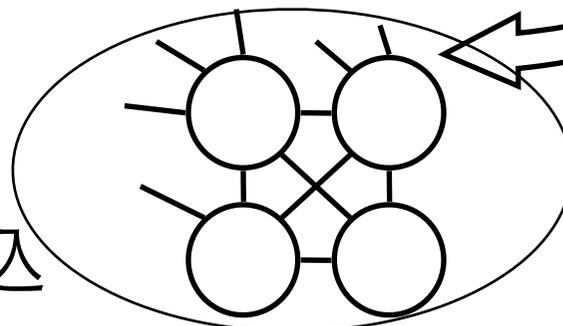
自己想起



相互想起



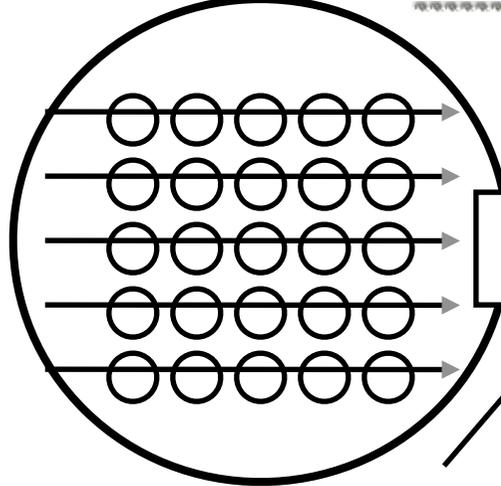
結合に
パターンを埋込



相互結合型ニューラルネットワーク

素子数 n

アソシアトロン, ホップフィールドネット



$$\mathbf{p} = [11111-1-1-1\cdots 11111]$$

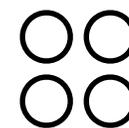
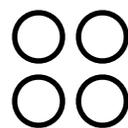
1:黒 (発火), -1:白 (非発火)

このようなベクトルパターンを用いて、

$$\boxed{n \times n} \longrightarrow \mathbf{W} = \sum_i \mathbf{p}_i^T \mathbf{p}_i$$

パターンを埋め込む

例題：記憶パターン



$$a = [111-1] \quad b = [-1-111]$$

$$W = a^T a + b^T b = \begin{bmatrix} 1 \\ 1 \\ 1 \\ -1 \end{bmatrix} [111-1] + \begin{bmatrix} -1 \\ -1 \\ 1 \\ 1 \end{bmatrix} [-1-111]$$

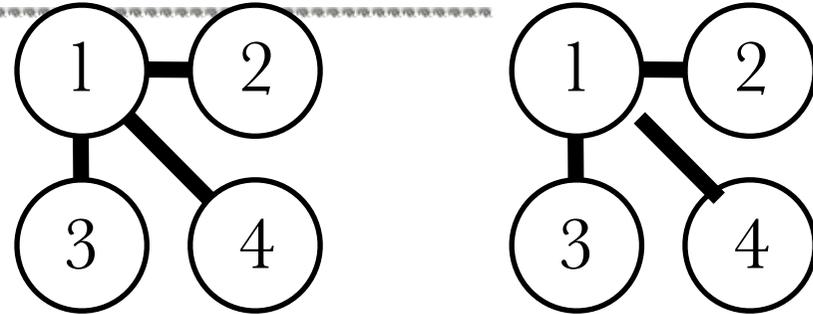
$$= \begin{bmatrix} 1 & 1 & 1 & -1 \\ 1 & 1 & 1 & -1 \\ 1 & 1 & 1 & -1 \\ -1 & -1 & -1 & 1 \end{bmatrix} + \begin{bmatrix} 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & -1 \\ -1 & -1 & 1 & 1 \\ -1 & -1 & 1 & 1 \end{bmatrix} = \begin{bmatrix} 2 & 2 & 0 & -2 \\ 2 & 2 & 0 & -2 \\ 0 & 0 & 2 & 0 \\ -2 & -2 & 0 & 2 \end{bmatrix}$$

例題： 記憶パターン $a = [111-1]$ $b = [-1-111]$

重みベクトル

W

0	2	0	-2
2	0	0	-2
0	0	0	0
-2	-2	0	0



同じ符号+

違う符号-

ニューロン同士の相関

想起実験

記憶パターン $\begin{matrix} \circ\circ \\ \circ\circ \end{matrix}$

$$a = [1\ 1\ 1\ -1] \quad b = [-1\ -1\ 1\ 1]$$

$$y = a'W = [1\ 1\ \overset{\text{ノイズ}}{\circledast} -1] \begin{bmatrix} 0 & 2 & 0 & -2 \\ 2 & 0 & 0 & -2 \\ 0 & 0 & 0 & 0 \\ -2 & -2 & 0 & 0 \end{bmatrix} = [4\ 4\ 0\ -4]$$

今我々が知りたいのは、正負のみ \rightarrow sgn

$$\text{sgn}^{(x)}([4\ 4\ 0\ -4]) = [1\ 1\ 1\ -1] = a$$

$\begin{matrix} \circ\circ \\ \circ\circ \end{matrix}$

想起実験 2 記憶パターン $a = [1\ 1\ 1\ -1]$ $b = [-1\ -1\ 1\ 1]$

演習

○○
○○

$$y' = b'W = \begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ -2 & -2 & 0 & 0 \end{bmatrix} = \begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \end{bmatrix}$$

今我々が知りたいのは、正負のみ \rightarrow sgn

$$\text{sgn} \left(\begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \end{bmatrix}^{(x)} \right) = \begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \end{bmatrix} =$$

○○
○○

想起実験 2 記憶パターン $a = [111-1]$ $b = [-1-111]$

演習

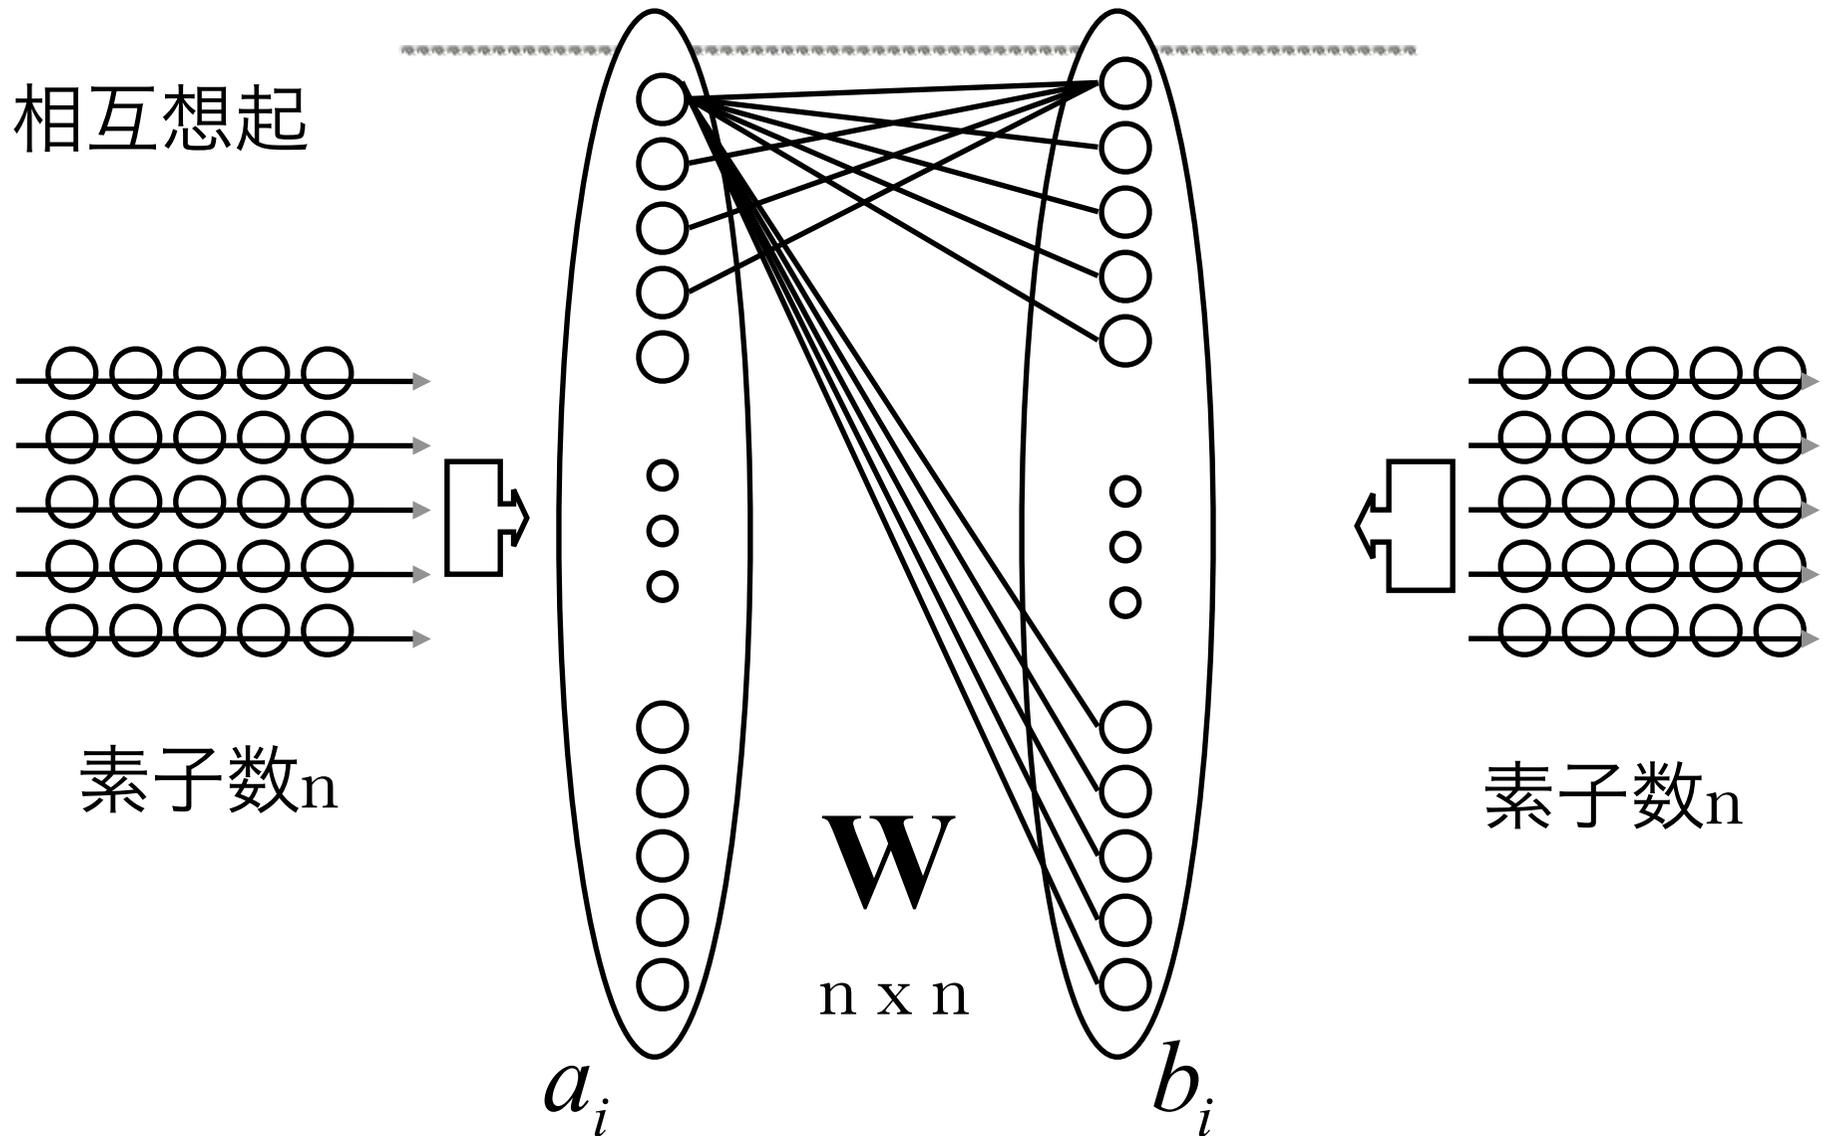
$$y' = b'W = \begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ -2 & -2 & 0 & 0 \end{bmatrix} = \begin{bmatrix} \circ & \circ & \circ & \circ \end{bmatrix}$$

今我々が知りたいのは、正負のみ \rightarrow sgn

$$\text{sgn} \left(\begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \end{bmatrix}^{(x)} \right) = \begin{bmatrix} \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \\ \circ & \circ & \circ & \circ \end{bmatrix} =$$

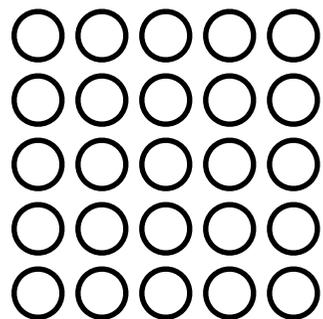
相互結合型ニューラルネットワーク

BAM(Bi-directional Associative Memory)

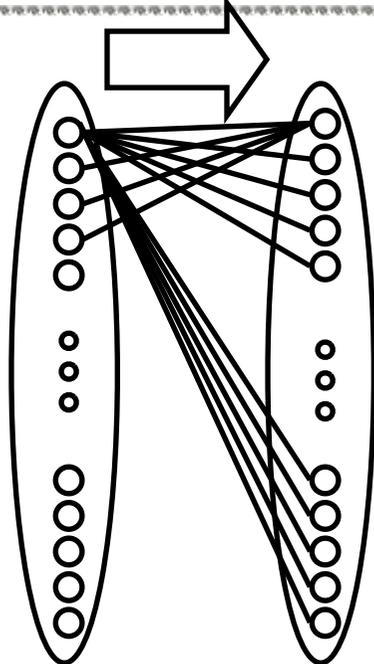
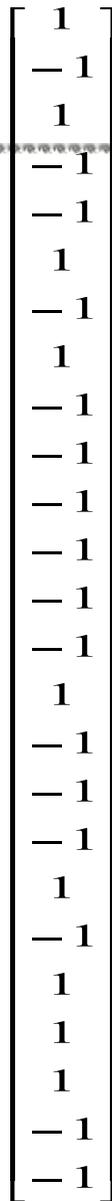


BAM

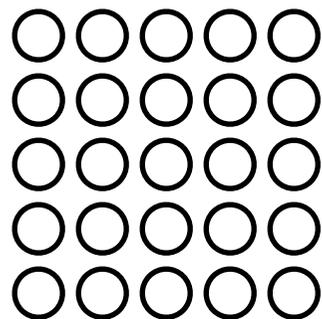
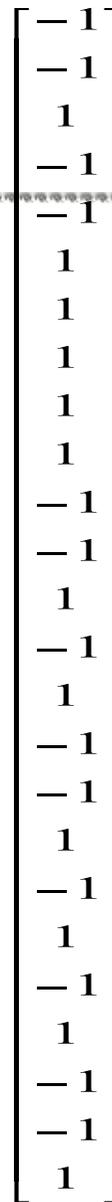
$$\mathbf{W} = \sum_i a_i b_i^T$$



$a =$



$b =$



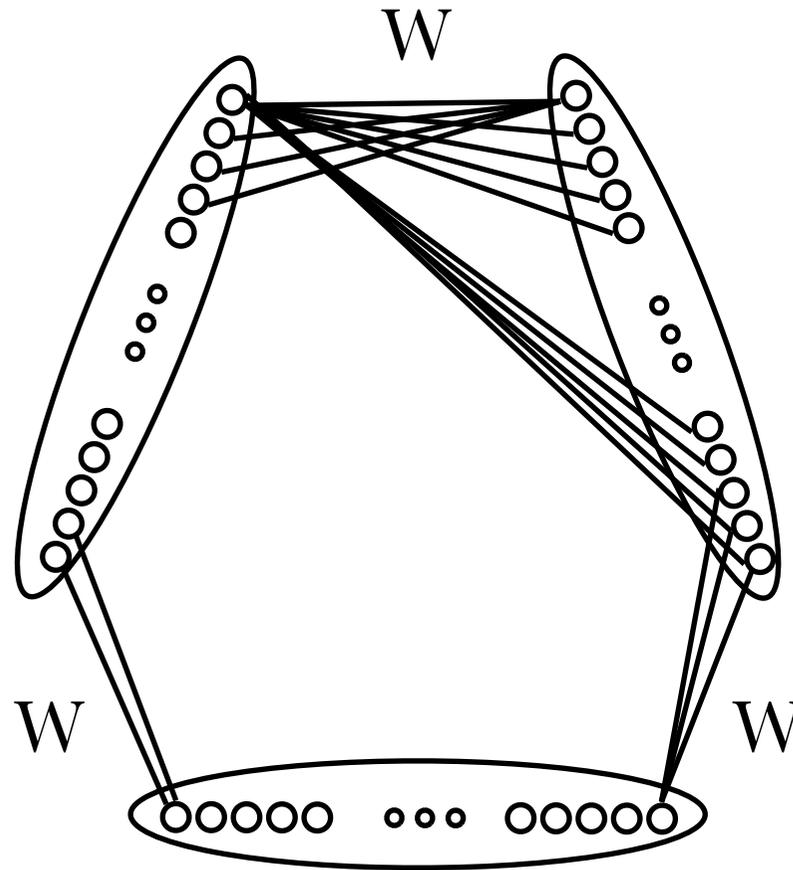
参考

$$\mathbf{W} = \sum_i \mathbf{p}_i^T \mathbf{p}_i$$

$$\mathbf{W}^T = \sum_i b_i a_i^T$$

MAM (Multidirectional Associative Memory)

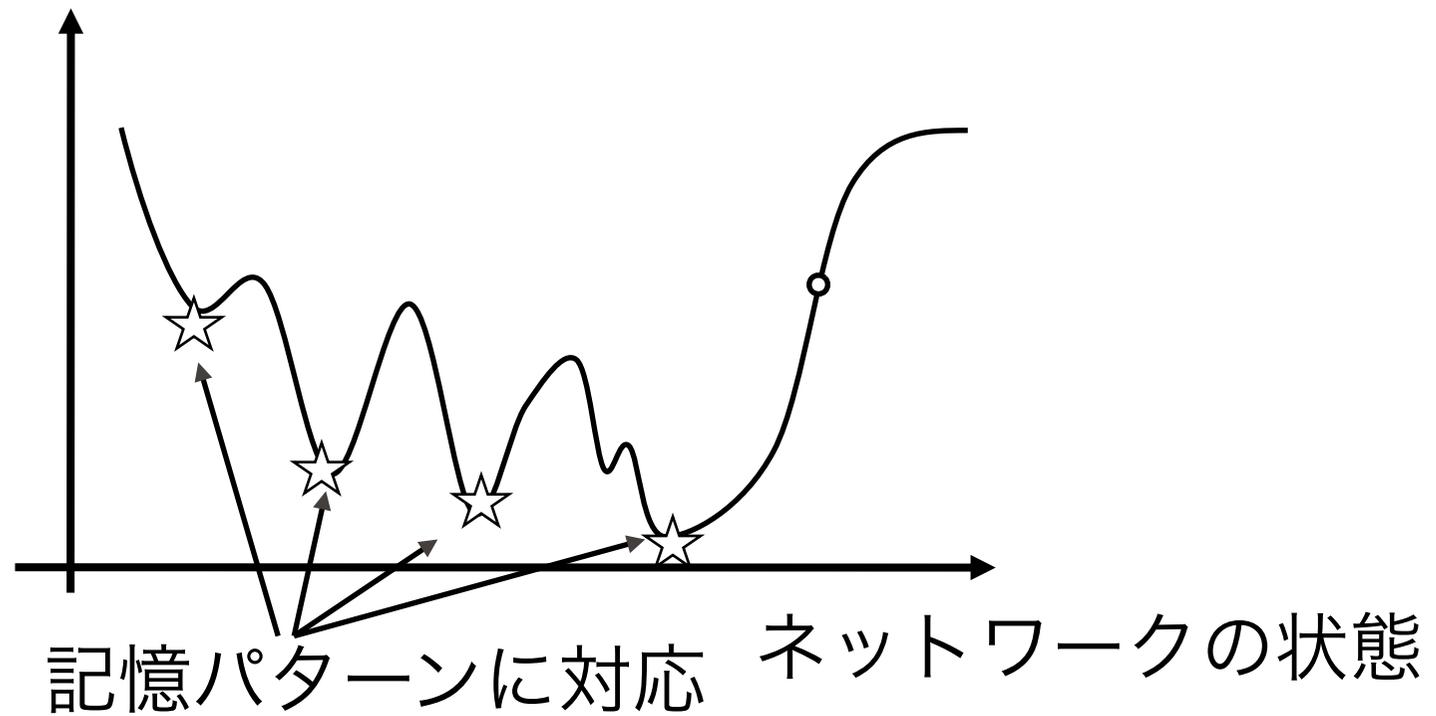
多段



相互結合型ニューラルネットワーク による連想記憶装置

- ❖ 情報の欠落を補完：並列性
- ❖ 記憶容量少
 - ❖ 素子数 n : 記憶可能なパターン数 $0.15 n$
 - ❖ 必要な結合数 : $n \times n$
 - ❖ 記憶パターン同士の相関少 : 直交化等が必要

ネットワークのエネルギー

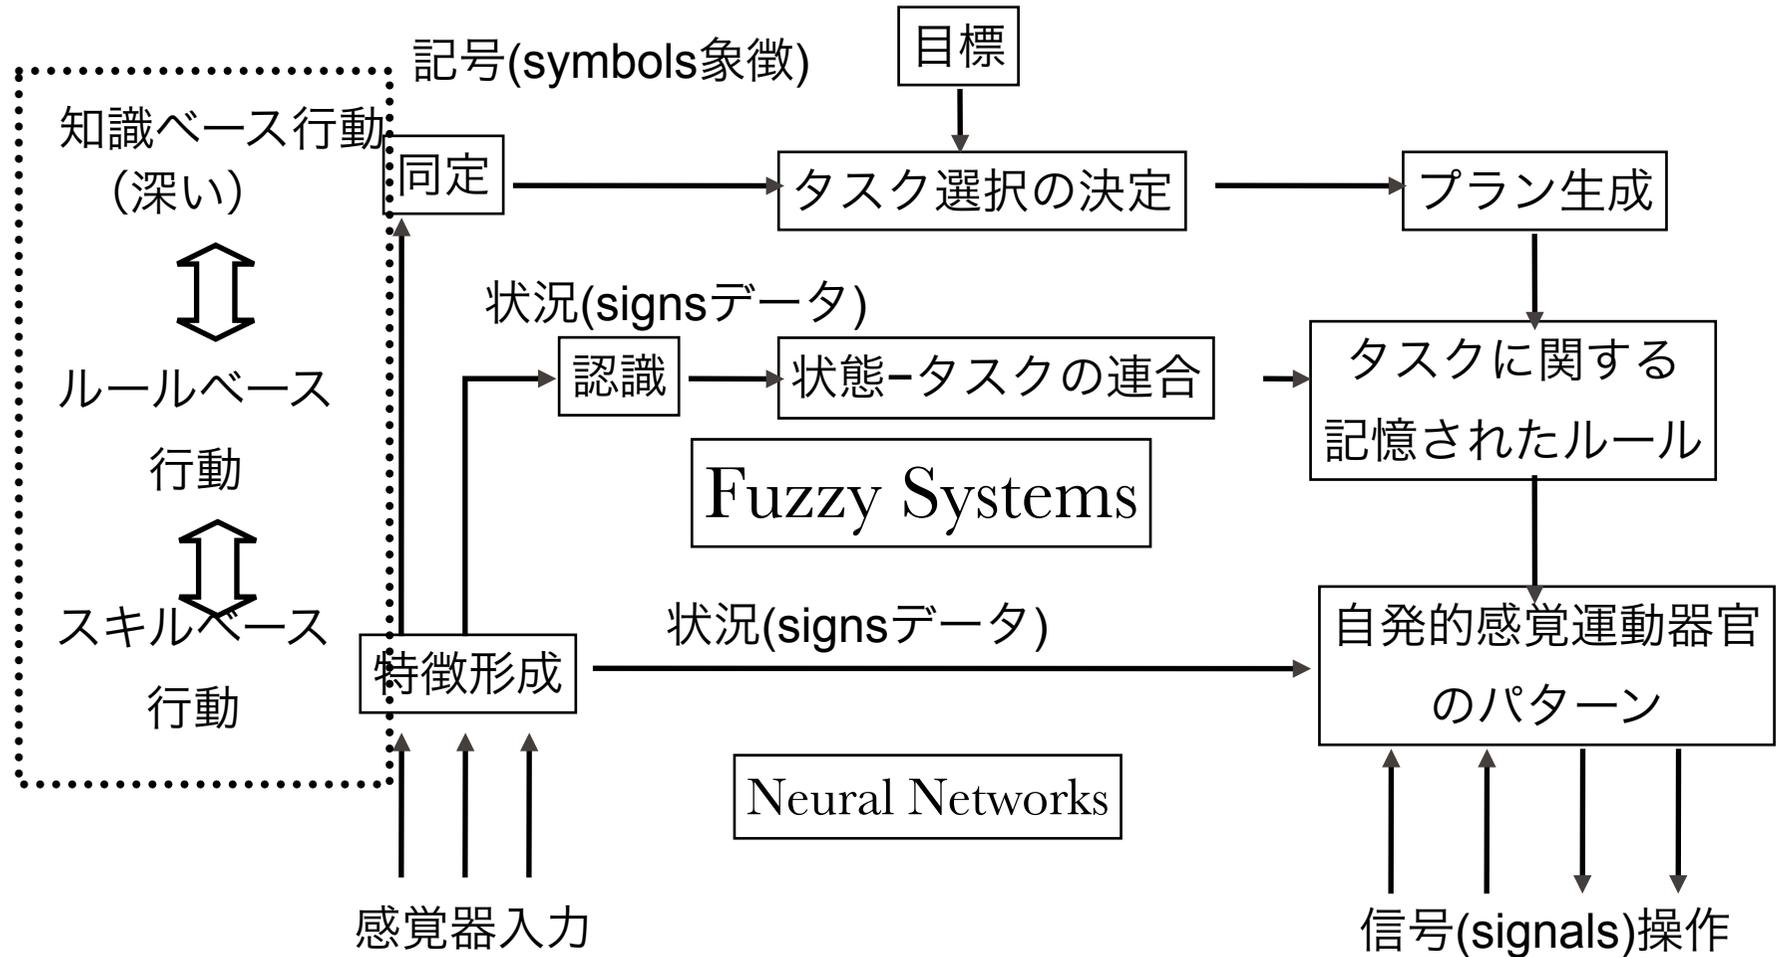


脳の情報処理の様式

- ❖ 論理的思考
 - ❖ 公理・記号・推論規則 → 定理の体系
 - ❖ 計算可能性の理論（（万能）Turing機械）
 - （ノイマン型）コンピュータ
- ❖ 直感的思考
 - ❖ 全体の構図を把握 → 答の方向を探す

人間の行動様式分析

Rusmussen 1980



視覚情報処理の過程

分解による特徴抽出

→ 線分 ^{統合}

網膜



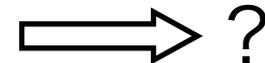
- ・ 方位
- ・ 位置
- ・ 長さ



コラム構造

モジュール化

おばあさん細胞



- ・ 中程度に複雑な図形

1959 Hubel&Wiesel

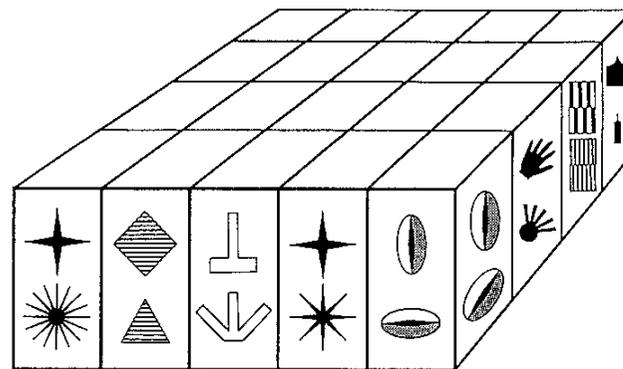


図 4.13 TE 野のコラム構造を表す模式図

田中, 対象認知の脳内メカニズム, (甘利, 酒田編: 脳とニューラルネット, 朝倉書店) より

1996 Tanaka

コラム構造の機能的意味

- 図形特徴の単位の表出

 - ばらつき → 頑健性（似た特徴を同じとみなす）

- 図形特徴の違いの連続的表出

 - コラム内での活動の（空間的）分布により、違いを表す

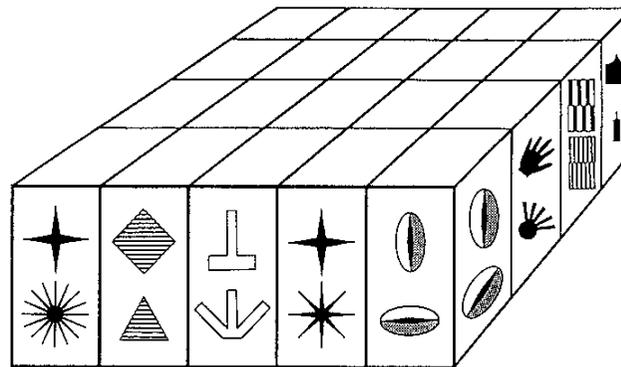


図 4.13 TE 野のコラム構造を表す模式図

脳内での情報表現

- 情報の基本コード

1. おばあさん細胞表現

2. 分散表現

3. スパース表現

イヌ	○	○	○	○	○	○	○	○	○
ネコ	○	○	○	○	○	○	○	○	○
トリ	○	○	○	○	○	○	○	○	○
リンゴ	○	○	○	○	○	○	○	○	○
ツクエ	○	○	○	○	○	○	○	○	○

+ 実験的事実

— 有限個のニューロンで無限の事象に対応できるか？

— 多数のニューロンが 万/日で死滅→情報の破壊は無

— 情報間の類似度をどの様に表現できるか？

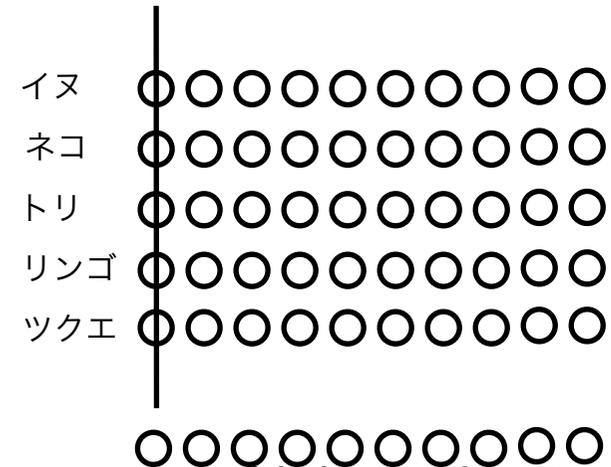
脳内での情報表現

❖ 情報の基本コード

– おばあさん細胞表現

❖ 分散表現

– スパース表現



脳全体でN個のニューロン、n個のニューロンで情報を表現

・ 重複を認めない： N/n (おばあちゃん細胞+頑健性)

・ 重複を認める： NC_n ($10C_3=120$)

重複が大 → 弁別性が低くなる

ノイズに弱い、機能代償が難しい

脳内での情報表現

❖ 情報の基本コード

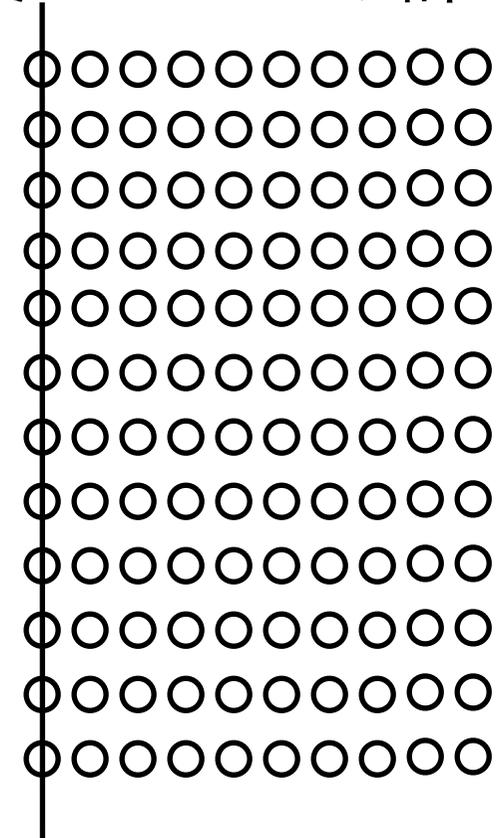
- おばあさん細胞表現
- 分散表現

❖ スパース(sparse)表現

- 分散表現において、重複が大 →
 弁別性が低くなる
- 部分的で適度な重複 ??

$N=10, n=3$

重複を1つだけ許す



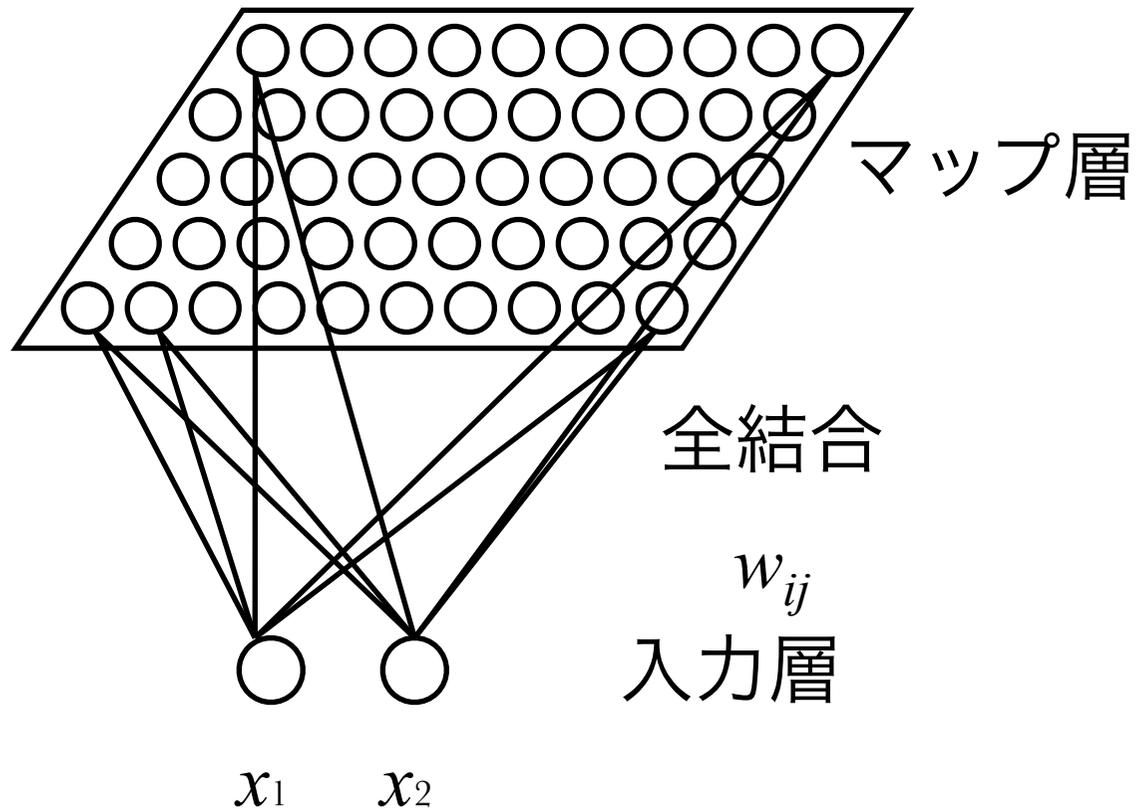
ニューラルネットワーク いろいろ

- ❖ 階層型ニューラルネットワーク (BP学習)
 - ❖ 任意の非線形写像のモデリング
 - Fuzzyシステムとの融合
- ❖ 相互結合型ニューラルネットワーク
 - ❖ 連想記憶
 - ❖ 自己組織化特徴マップ
 - ❖ 学習ベクトル量子化

❖ 自己組織化特徴マップ (Kohonen)

- 教師無し学習
- 入力データの特徴を自動抽出・学習
- 似た入力をネットワーク中の近くに配置

ネットワーク構造



自己組織化マップの学習アルゴリズム

1. 初期化

乱数により層間結合を初期化

2. マップ層にて入力ベクトルとの距離を計算

$$d_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2}$$

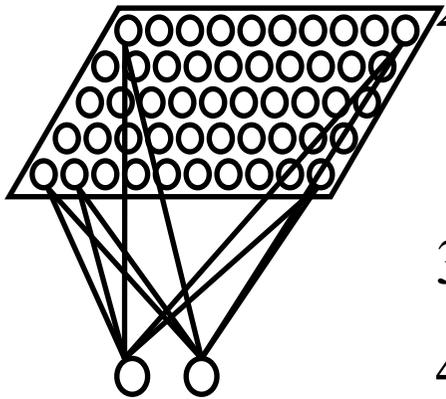
3. 距離が最小のニューロンを選択

4. 層間結合の更新 (学習)

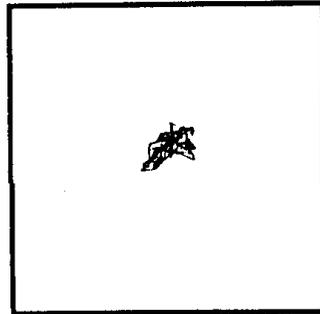
$$\Delta w_{ij} = \eta h(j, j^*) (x_i - w_{ij})$$

$$h(j, j^*) = \exp\left(\frac{-|j - j^*|^2}{\sigma(t)^2}\right)$$

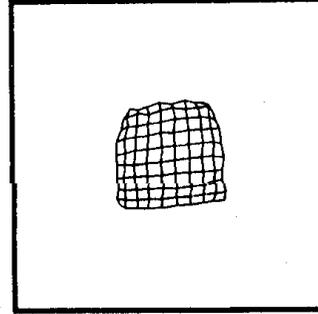
$h(j, j^*)$: 近傍関数



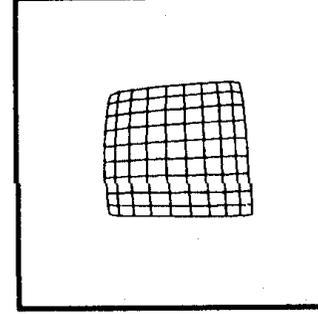
自己組織化マップでできること



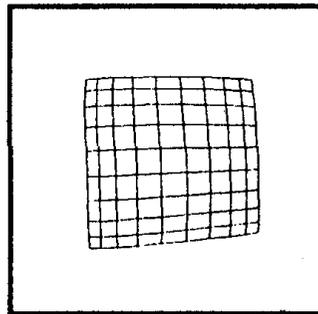
(a) 100回学習終了後



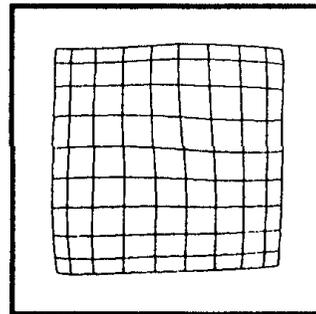
(b) 500回学習終了後



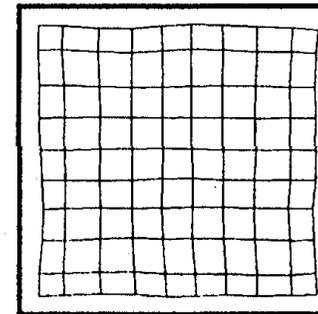
(c) 1000回学習終了後



(d) 2000回学習終了後



(e) 5000回学習終了後



(f) 10000回学習終了後

図 3.15 自己組織化特徴マップ形成のシミュレーション (入力ベクトルは2次元, マップ層は100 (10×10). 図は, マップ層各ニューロンの入力層からの重みベクトルを示す)

ニューラルネットワーク いろいろ

- ❖ 階層型ニューラルネットワーク (BP学習)
 - ❖ 任意の非線形写像のモデリング
 - Fuzzyシステムとの融合
- ❖ 相互結合型ニューラルネットワーク
 - ❖ 連想記憶
 - ❖ 自己組織化特徴マップ
 - ❖ 学習ベクトル量子化

❖ 学習ベクトル量子化

(Learning Vector Quantization: LVQ)

- 教師あり学習
- 情報圧縮
- 似た入力をまとめて一つのニューロンで代表

LVQのアルゴリズム

1. 初期化

乱数により層間結合を初期化

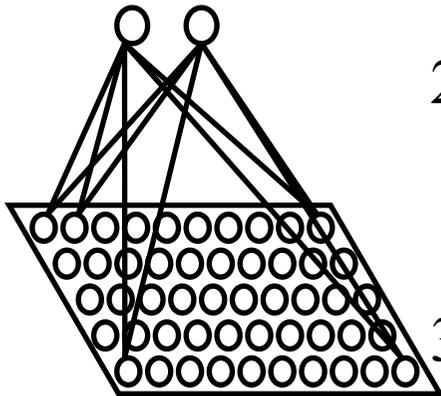
2. マップ層にて入力ベクトルとの距離を計算

$$d_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2}$$

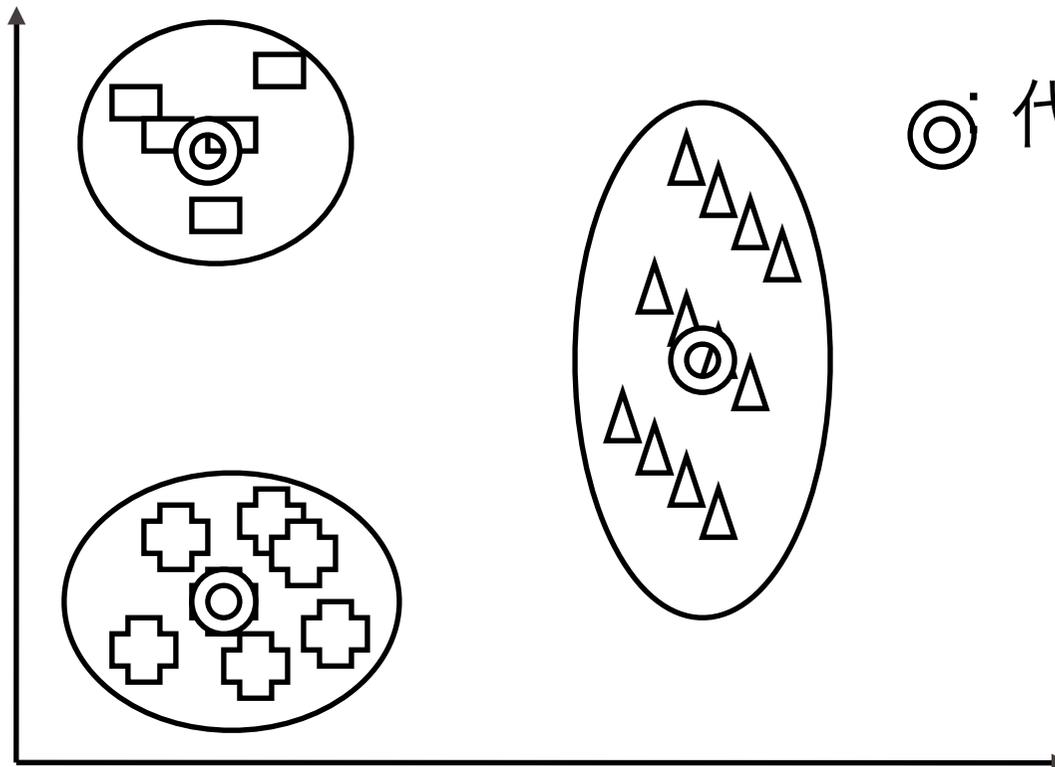
3. 距離が最小のニューロンを選択

4. 層間結合の更新 (学習)

$$\Delta w_{ij} = \begin{cases} +\eta(x_i - w_{ij}) & \text{正しく識別} \\ -\eta(x_i - w_{ij}) & \text{誤って識別} \end{cases}$$



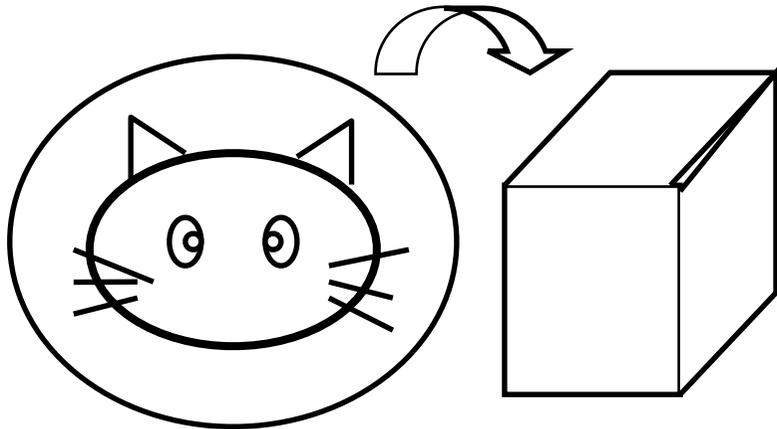
LVQでできること



◎ 代表ベクトル

遺伝と学習

(先天・後天)

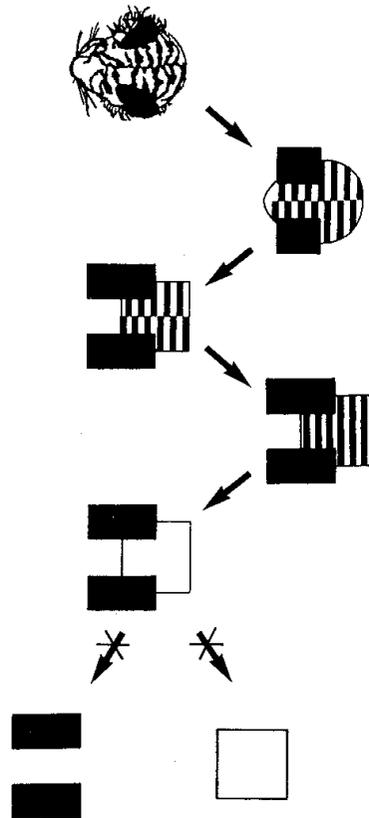


縦縞の世界

縦の線分に反応する
ニューロンが多数

横縞 少

モデリング



? 遺伝的に決定していること

? コラム構造を作る

? 環境に対して学習すること

? コラムが何に反応するか

設計

- 可調整パラメータ
- 固定パラメータ
- 固定構造

田中, 対象認知の脳内メカニズム, (甘利, 酒田編: 脳とニューラルネット, 朝倉書店) より