

# ニューラルシステムにおけるカオス

## 非線形システム特論

池口 徹

埼玉大学 大学院 理工学研究科 情報数理学専攻

338-8570 さいたま市 桜区 下大久保 255

Tel : 048-858-3577, Fax : 048-858-3716

Email : tohru@ics.saitama-u.ac.jp

URL : <http://www.nls.ics.saitama-u.ac.jp/~tohru>

# 内容

## 1. 神経系

- ◀ 構造
- ◀ ヤリイカと電気生理学
- ◀ 神経膜とその等価回路
- ◀ 活動電位
- ◀ Hodgkin-Huxley 方程式

## 2. 神経細胞のモデル化とニューロコンピューティング

- ◀ McCulloch-Pitts (形式ニューロン) モデル
- ◀ Caianiello モデル
- ◀ 南雲-佐藤 モデル
- ◀ カオスニューロン, カオスニューラルネットワークモデル

## 3. カオスニューラルネットワークの応用

- ◀ 動的連想記憶
- ◀ 組み合わせ最適化問題

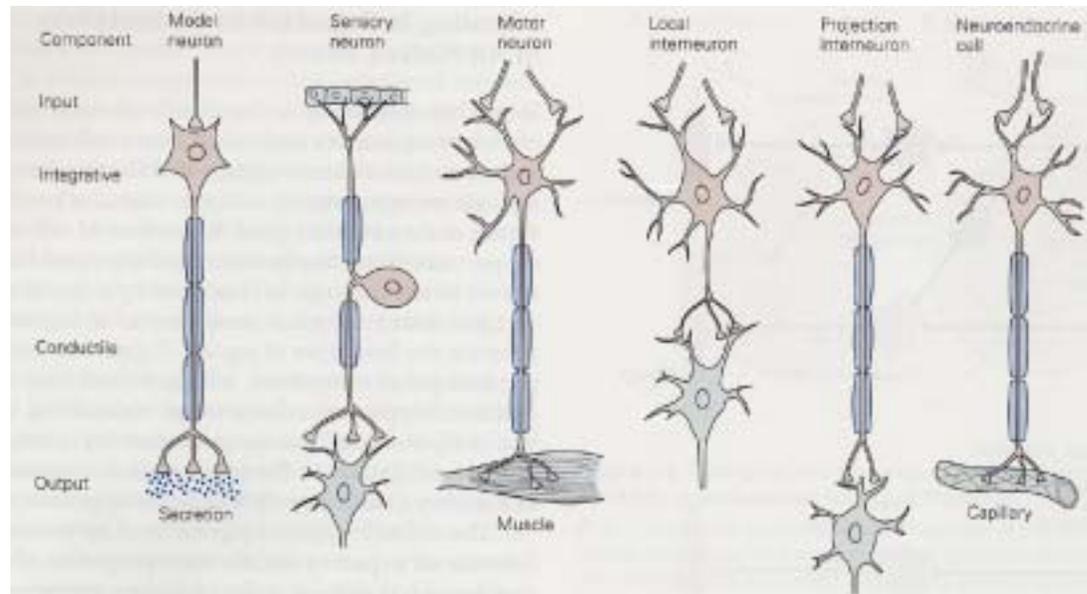
# ニューロコンピューティング

- ◀ ヤリイカ巨大軸索やそれを (現象論的に) モデル化した Hodgkin – Huxley 方程式  
⇒ 1次元写像で近似的に表現できる
- ◀ この後にはネットワーク化したい
- ◀ できればシンプルにもしたい
- ◀ あまりにヤリイカに依存したモデルを作っても、まずい場合もある。
- ◀ 過去の源流は ...
  - McCulloch – Pitts のモデル
  - Caianiello のモデル

# ニューロンの構造

## ◀ ニューロンの有する主要な機能

1. 入力を受ける
2. 積分
3. 伝送
4. 出力を伝える



# ニューロンモデル

## ◀ McCulloch & Pitts モデル

$$x(t + 1) = 1 \left[ \sum_{i=1}^N w_i s_i(t) - \theta \right]$$

## ◀ Caianiello のモデル

$$x(t + 1) = 1 \left[ \sum_{i=1}^N \sum_{r=0}^t T_i^{(r)} s_i(t - r) - \theta \right]$$

# 南雲-佐藤ニューロン

不応性を有するニューロンモデル

発火した直後は、発火しにくくなる性質

◀ 南雲-佐藤ニューロンモデル (Nagumo & Sato, 1972)

$$x(t+1) = u \left[ A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right]$$

$k$  : 不応性の減衰定数

$\alpha (> 0)$  : 不応性の強度

$A(t)$  : ニューロンへの入力

$\theta$  : 閾値

$u(\cdot)$  : 出力 (活性化) 関数  $\Rightarrow$  ステップ関数

# 南雲-佐藤ニューロンの不応性

$$x(t+1) = u \left[ A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right] = u[y(t+1)]$$

$$\begin{aligned} y(t+1) &= A(t) - \alpha \{ k^0 x(t) + k^1 x(t-1) + \dots + k^{t-1} x(1) + k^t x(0) \} - \theta \\ &= A(t) - \alpha \{ x(t) + k^1 x(t-1) + \dots + k^{t-1} x(1) + k^t x(0) \} - \theta \end{aligned}$$

# 南雲-佐藤ニューロンの不応性

$$x(t+1) = u \left[ A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right] = u[y(t+1)]$$

$$\begin{aligned} y(t+1) &= A(t) - \alpha \{ k^0 x(t) + k^1 x(t-1) + \dots + k^{t-1} x(1) + k^t x(0) \} - \theta \\ &= A(t) - \alpha \{ x(t) + k^1 x(t-1) + \dots + k^{t-1} x(1) + k^t x(0) \} - \theta \end{aligned}$$



過去の発火情報が次時刻の発火に影響を与える

# 南雲-佐藤ニューロンの不応性

$$x(t+1) = u \left[ A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right] = u[y(t+1)]$$

$$\begin{aligned} y(t+1) &= A(t) - \alpha \{ k^0 x(t) + k^1 x(t-1) + \dots + k^{t-1} x(1) + k^t x(0) \} - \theta \\ &= A(t) - \alpha \{ x(t) + k^1 x(t-1) + \dots + k^{t-1} x(1) + k^t x(0) \} - \theta \end{aligned}$$



過去の発火情報が次時刻の発火に影響を与える



$0 < k < 1, \alpha > 0$  とすれば,

過去に発火すれば, 次時刻は発火しにくい  $\iff$  不応性

# 南雲-佐藤ニューロンと1次元写像

$$x(t+1) = u \left[ A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right]$$

において,

$$y(t+1) = A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta$$

とおくと,

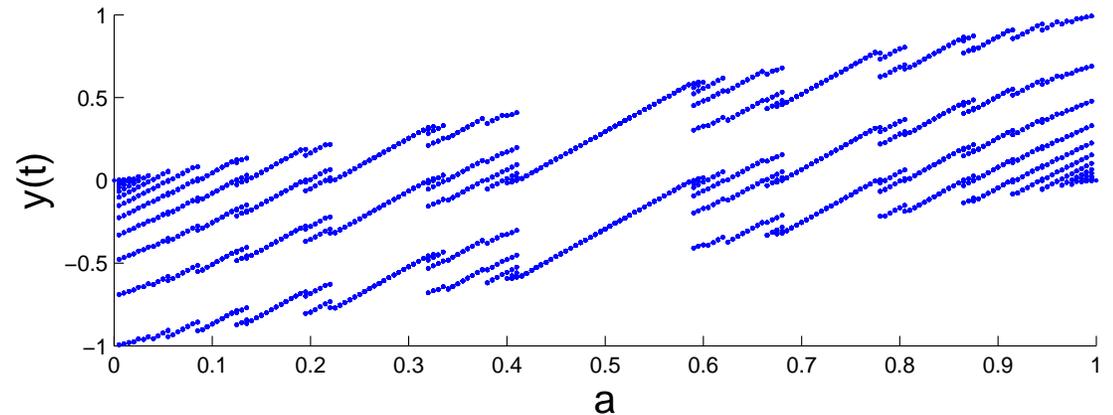
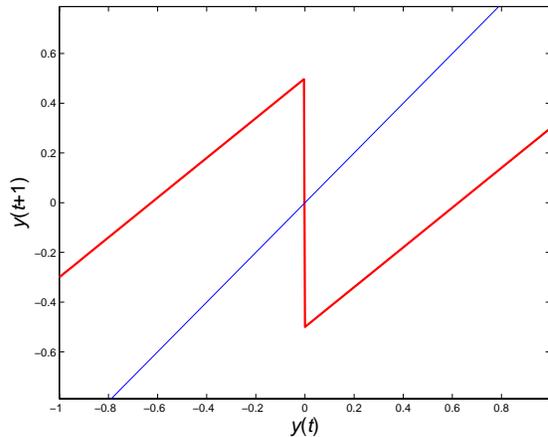
$$y(t+1) = ky(t) - \alpha u[y(t)] + (A(t) - \theta)(1 - k)$$

となる.  $A(t) = A(\text{一定})$  とすると  $a = (A - \theta)(1 - k)$

$$y(t+1) = ky(t) - \alpha u[y(t)] + a \quad \text{1次元写像}$$

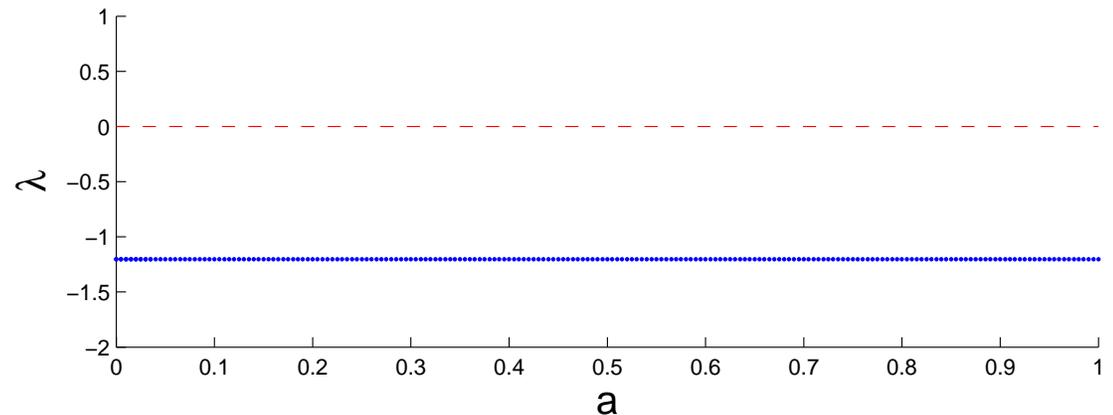
# 南雲-佐藤ニューロンの応答特性

$$y(t+1) = ky(t) - \alpha u[y(t)] + a = F(y(t)), t \in \mathbb{Z}$$



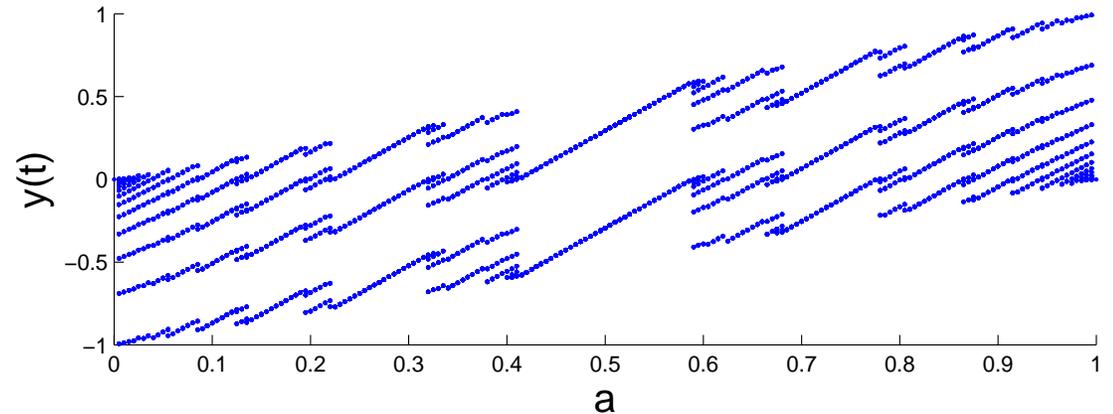
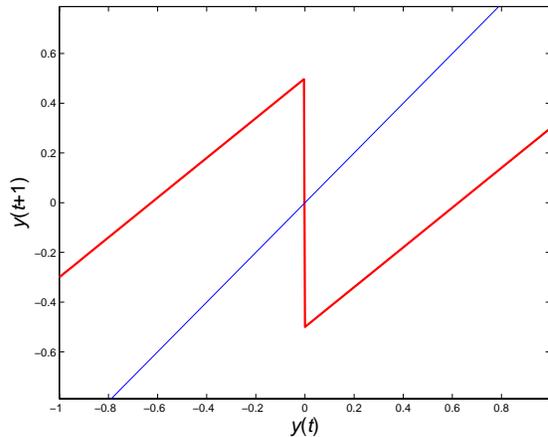
リアプノフ指数

$$\lambda = \lim_{L \rightarrow \infty} \frac{1}{L} \sum_{t=0}^{L-1} \log \left| \frac{dF(y(t))}{dy(t)} \right|$$



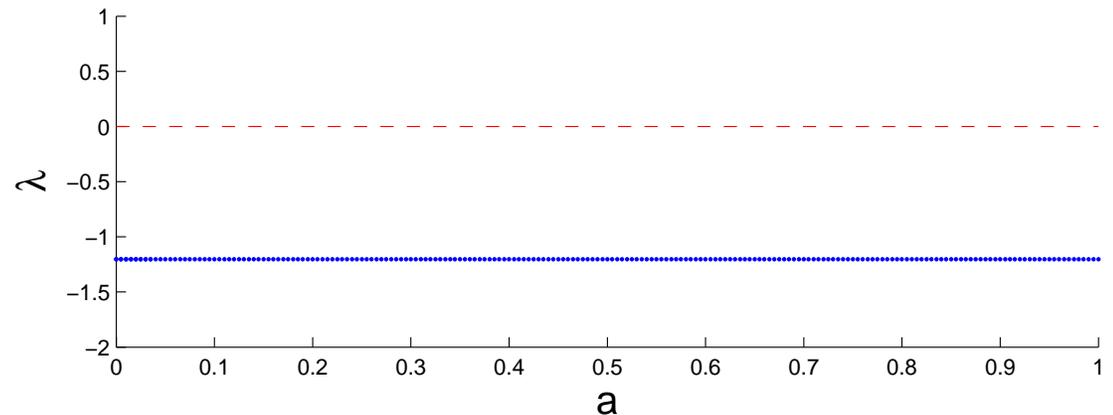
# 南雲-佐藤ニューロンの応答特性

$$y(t+1) = ky(t) - \alpha u[y(t)] + a = F(y(t)), t \in \mathbb{Z}$$



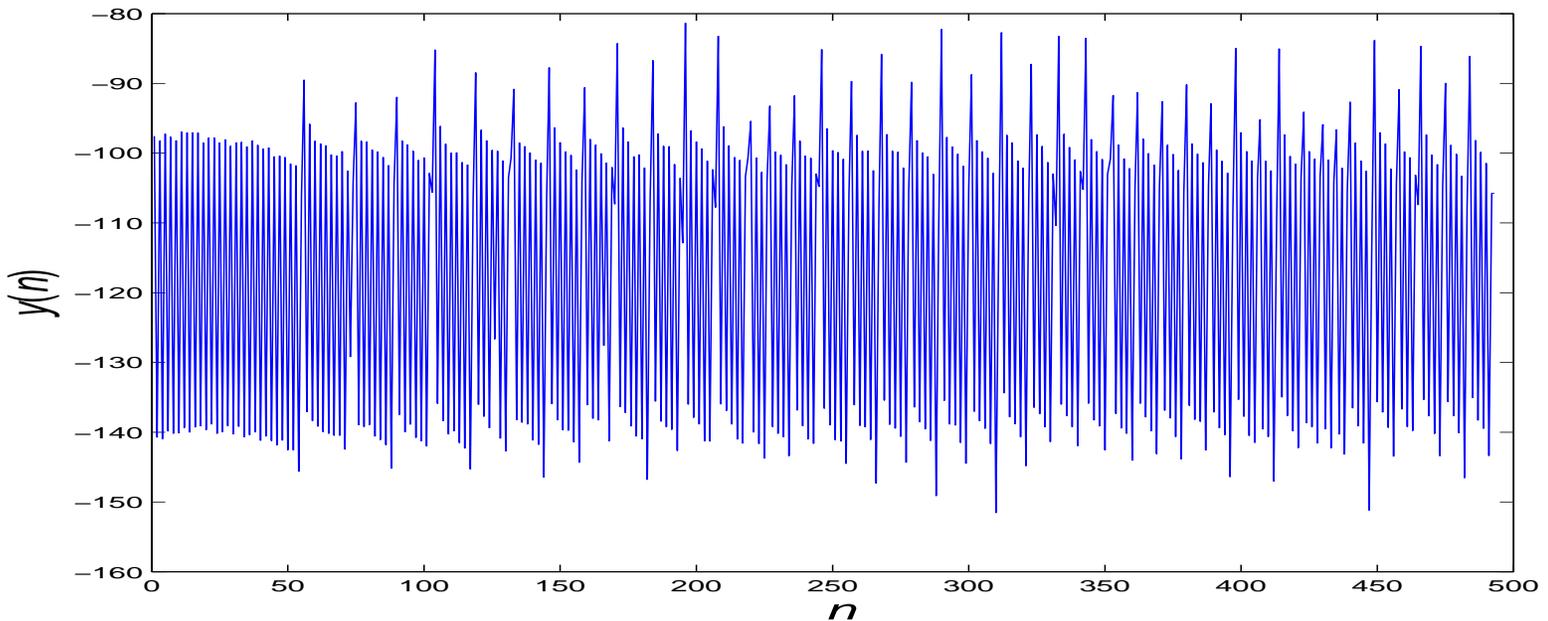
リアプノフ指数

$$\lambda = \lim_{L \rightarrow \infty} \frac{1}{L} \sum_{t=0}^{L-1} \log \left| \frac{dF(y(t))}{dy(t)} \right|$$



南雲-佐藤ニューロンモデルではカオス応答を再現できない

# ヤリイカ巨大軸索におけるカオス



- ◀ 南雲-佐藤ニューロンモデルではカオス応答を再現できない
- ◀ 実際のニューロンでは，カオス応答が観測されている．

# カオスダイナミクスを創り出す

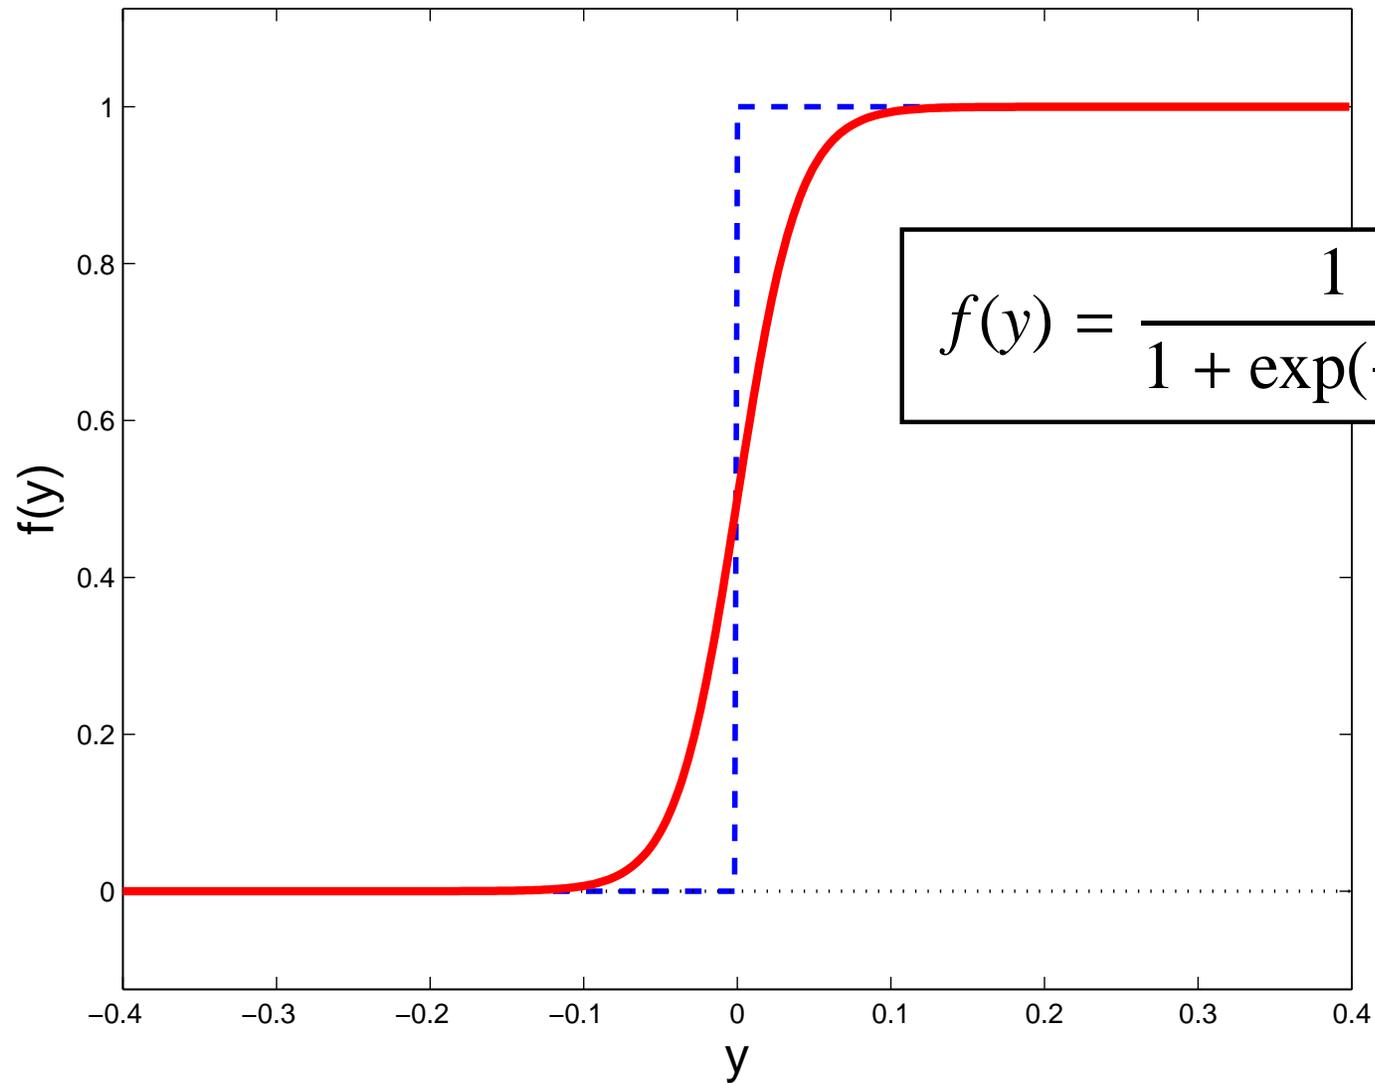
## 不応性を有するニューロンモデル

- ◀ 南雲-佐藤ニューロンモデル ⇒ カオス応答再現不能
- ◀ カオスニューロン (Aihara, Takabe, Toyoda, 1990)

$$x(t+1) = f \left[ A(t) - \alpha \sum_{d=0}^t k^d g\{x(t-d)\} - \theta \right]$$

- $k$  : 不応性の減衰定数
- $\alpha (> 0)$  : 不応性の強度
- $A(t)$  : ニューロンへの入力
- $\theta$  : 閾値
- $f(\cdot)$  : 出力 (活性化) 関数 ⇒ シグモイド関数

# ステップ関数とシグモイド関数



# カオスニューロンと1次元写像

$$x(t+1) = f \left[ A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right]$$

において,

$$y(t+1) = A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta$$

とおくと,

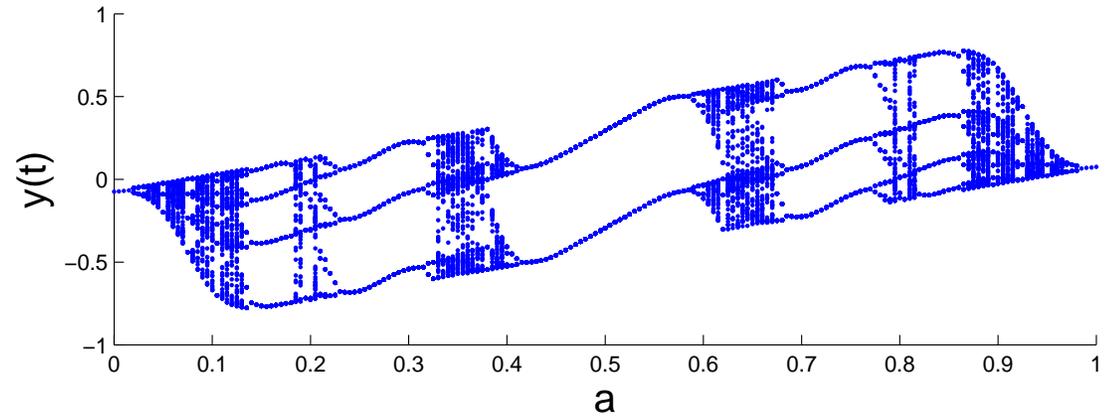
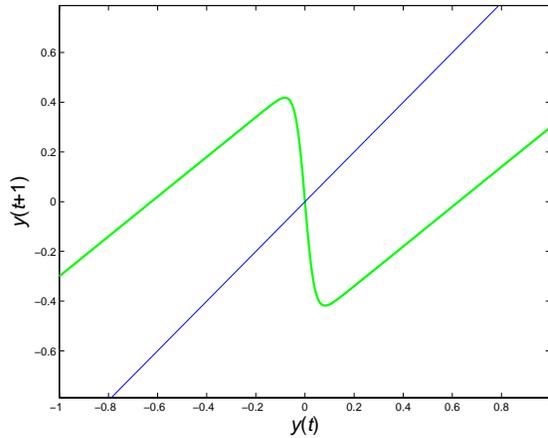
$$y(t+1) = ky(t) - \alpha u[y(t)] + (A(t) - \theta)(1 - k)$$

となる.  $A(t) = A(\text{一定})$  とすると  $a = (A - \theta)(1 - k)$

$$y(t+1) = ky(t) - \alpha f[y(t)] + a \quad \text{1次元写像}$$

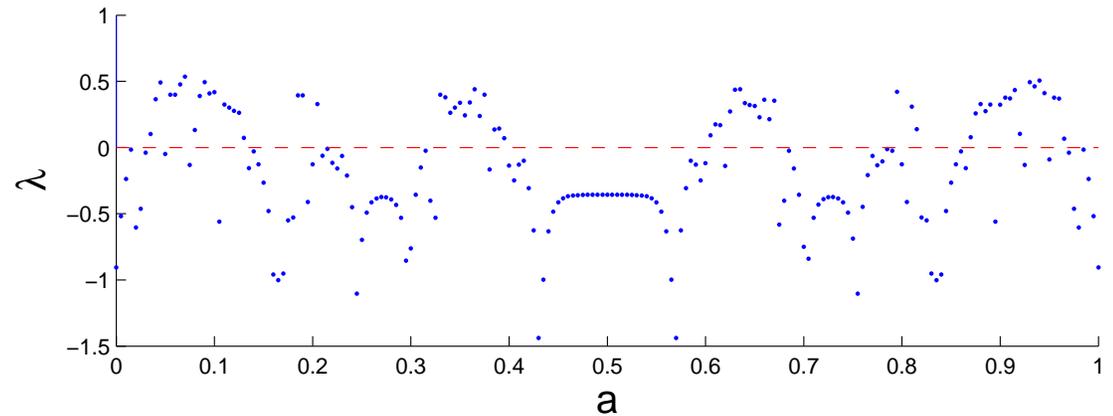
# カオスニューロンの応答特性

$$y(t+1) = ky(t) - \alpha f[y(t)] + a = F(y(t)), t \in \mathbb{Z}$$



リアプノフ指数

$$\lambda = \lim_{L \rightarrow \infty} \frac{1}{L} \sum_{t=0}^{L-1} \log \left| \frac{dF(y(t))}{dy(t)} \right|$$



# ニューラルネットワークの構築

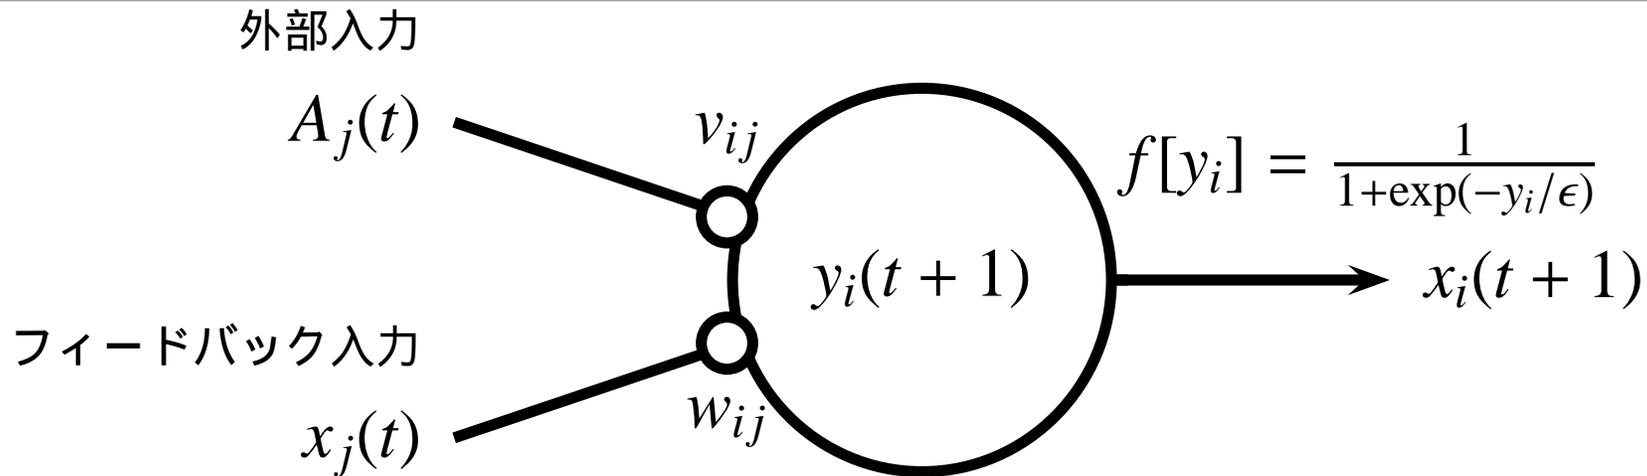
◀ (ある) ニューロンモデルを用いて, ニューラルネットワークを構成する際に重要な2つの結合形態

1. 相互結合
2. 層状結合



1. そのニューロンと同じニューラルネットワークからの入力 → フィードバック入力
2. そのニューロンと異なるニューラルネットワークからの入力 → 外部入力

# カオスニューラルネットワーク



$$\begin{aligned}
 x_i(t+1) = & f \left[ \sum_j^M v_{ij} \sum_{d=0}^t k_s^d A_j(t-d) \right. \\
 & \left. + \sum_j^N w_{ij} \sum_{d=0}^t k_m^d x_j(t-d) - \alpha \sum_{d=0}^t k_r^d x_i(t-d) - \theta_i \right]
 \end{aligned}$$

# カオスニューラルネットワーク

$$\left\{ \begin{array}{l} \xi_i(t+1) = \sum_{j=1}^M v_{ij} \sum_{d=0}^t k_s^d A_j(t-d) \\ \eta_i(t+1) = \sum_{j=1}^N w_{ij} \sum_{d=0}^t k_m^d x_j(t-d) \\ \zeta_i(t+1) = -\alpha \sum_{d=0}^t k_r^d x_i(t-d) - \theta_i \end{array} \right.$$

$$\Rightarrow \left\{ \begin{array}{l} \xi_i(t+1) = k_s \xi_i(t) + \sum_{j=1}^M v_{ij} A_j(t) \\ \eta_i(t+1) = k_m \eta_i(t) + \sum_{j=1}^N w_{ij} x_j(t) \\ \zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) - \theta_i \end{array} \right.$$

# 他のニューラルネットワークとの関係

出力関数	ステップ関数	シグモイド関数
$k = \alpha = 0$	McCulloch-Pitts 形式ニューロンモデル	Analog-Neuron Back Propagation
$k \neq 0, \alpha \neq 0$	Nagumo-Sato ニューロンモデル	Chaotic Neuron

## ◀ カオスニューラルネットワークの

- パラメータ
- 出力関数 (活性化関数)

を変化させることで、他のタイプのニューロンモデルを再現可能

# カオスニューラルネットワークの応用

## ◀ 連想記憶

- 動的な連想記憶
- カオスの遍歴

## ◀ 組み合わせ最適化問題

- 巡回セールスマン問題 (TSP)
- 2次割り当て問題 (QAP)

# 連想記憶

A → A

A → A

A → 優

# 連想記憶

## ◀ 静的な連想記憶

Nakano, 1972; Kohonen, 1972; Anderson, 1972;

□ 自己想起

□ 相互想起

## ◀ 動的な連想記憶 ⇒ 周期系列

Amari, 1972

## ◀ 「もっと」動的な連想記憶 ⇒ 非周期系列

# 相互結合型ニューラルネットのエネルギー

## ◀ ダイナミクス

$$x_i(t+1) = \begin{cases} 1 & \cdots & \sum_{j=1}^N w_{ij}x_j(t) > \theta_i \\ 0 & \cdots & \sum_{j=1}^N w_{ij}x_j(t) < \theta_i \end{cases}$$

### □ 仮定

1.  $w_{ij} = w_{ji}$
2.  $w_{ii} = 0$

□ この時，以下の関数 (エネルギー) を考える．

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij}x_i(t)x_j(t) + \sum_{i=1}^N \theta_i x_i(t)$$

# エネルギー最小化原理

- ◀ 第  $k$  番目のニューロンが  $x_k \rightarrow x_k + \Delta x_k$  に状態変化
- ◀ エネルギーの変化は,

$$\begin{aligned}\Delta E &= E(x_k + \Delta x_k) - E(x_k) \\ &= -\frac{1}{2}\Delta x_k \sum_{j=1}^N w_{kj}x_j - \frac{1}{2}\Delta x_k \sum_{i=1}^N w_{ik}x_i + \Delta x_k \theta_k \\ &= -\Delta x_k \sum_{j=1}^N w_{kj}x_j + \Delta x_k \theta_k = -\Delta x_k \left( \sum_{j=1}^N w_{kj}x_j - \theta_k \right)\end{aligned}$$

$$\left\{ \begin{array}{l} \Delta x_k > 0 \quad \cdots \quad \sum_j w_{kj}x_j - \theta_k > 0 \\ \Delta x_k < 0 \quad \cdots \quad \sum_j w_{kj}x_j - \theta_k < 0 \end{array} \right. \quad \text{なので,}$$

# エネルギー最小化原理

- ◀ どのようにニューロンの状態が更新しても，

$$E \leq 0$$

となるように，ニューラルネットワークは動作する．

- ◀ ある最小化問題があって，この問題の評価関数を，このエネルギー関数の形で表現できたとする．
- ◀ ニューラルネットワークは  $E$  を減少させるように動作するので，ニューラルネットワークにより，この問題の評価関数の最小値を探索するマシンを構成できる．

# 連想記憶への応用

◀  $n$ 次元ベクトル  $\mathbf{x}(t) = \begin{pmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_N(t) \end{pmatrix}$

◀ ダイナミクス

$$x_i(t+1) = f \left\{ \sum_{j=1}^N W_{ij} x_j(t) - \theta_i \right\}$$

◀ ダイナミクス

$$\mathbf{x}(t+1) = f(\mathbf{W}\mathbf{x}(t) - \boldsymbol{\theta})$$

# 連想記憶のダイナミクス

## ◀ ダイナミクス

$$\mathbf{x}(t+1) = f(\mathbf{W}\mathbf{x}(t) - \boldsymbol{\theta})$$

## ◀ あるパターンの組 $\mathbf{x}_\alpha$ ( $\alpha = 1, 2, \dots, m$ ) を与えたときに,

$$\mathbf{x}_\alpha = f(\mathbf{W}\mathbf{x}_\alpha - \boldsymbol{\theta}) = F(\mathbf{x}_\alpha)$$

## ◀ つまり, $\mathbf{x}_\alpha$ がネットワーク (離散力学系 $F$ ) の安定平衡点

## ◀ 結合係数を

$$W_{ij} = \sum_{\alpha=1}^m (2x_i^{(\alpha)} - 1)(2x_j^{(\alpha)} - 1)$$

とすればよい ( $\mathbf{x}_\alpha = \{x_1^{(\alpha)}, x_2^{(\alpha)}, \dots, x_N^{(\alpha)}\}$ )

# 連想記憶のダイナミクス

- ◀ このような結合係数の決め方でうまく行くのは、パターンの組  $x_\alpha$  ( $\alpha = 1, 2, \dots, m$ ) がお互いに直交しているとき。

$$\mathbf{x}_\alpha \cdot \mathbf{x}_\beta = N\delta_{\alpha\beta}$$

- ◀ 例えば  $N = 16$  とすると

```
1 1 1 1 1 1 1 1 0 0 0 0 0 0 0 0
1 1 1 1 0 0 0 0 1 1 1 1 0 0 0 0
1 1 0 0 1 1 0 0 1 1 0 0 1 1 0 0
1 0 1 0 1 0 1 0 1 0 1 0 1 0 1 0
```

のようによければ良い。

# 連想記憶

## ◀ 静的な連想記憶

Nakano, 1972; Kohonen, 1972; Anderson, 1972;

### □ 自己想起

$$\mathbf{x}_\alpha = f(W\mathbf{x}_\alpha - \theta) = F(\mathbf{x}_\alpha)$$

### □ 相互想起

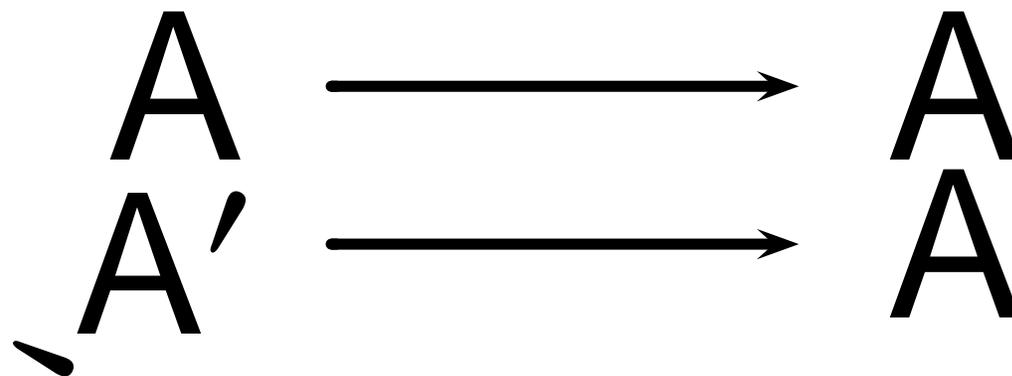
$$\mathbf{y}_\alpha = f(W\mathbf{x}_\alpha - \theta) = F(\mathbf{x}_\alpha)$$

## ◀ 動的な連想記憶 ⇒ 周期系列 (Amari, 1972)

$$\mathbf{x}_1 \rightarrow \mathbf{x}_2 \rightarrow \mathbf{x}_3 \rightarrow \mathbf{x}_4 \rightarrow \mathbf{x}_1$$

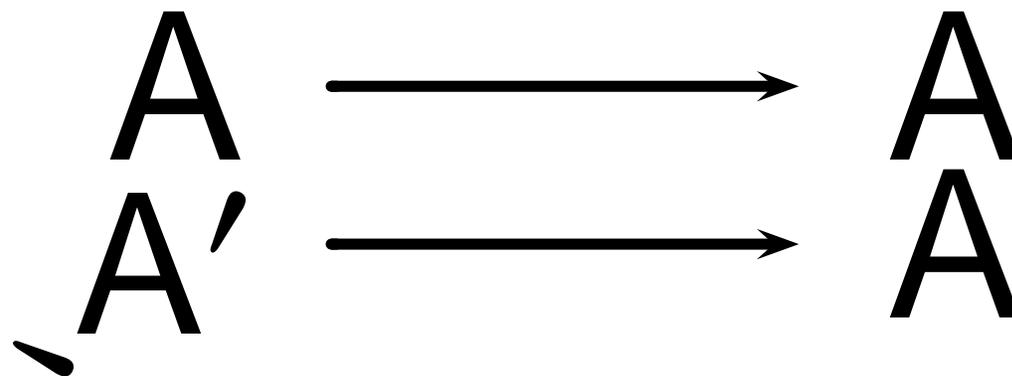
## ◀ 「もっと」動的な連想記憶 ⇒ 非周期系列

# もっと動的な連想記憶



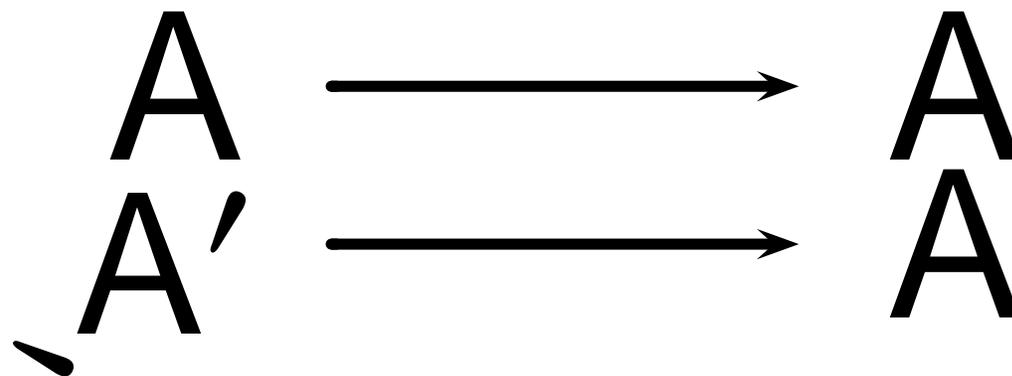
A → 優

# もっと動的な連想記憶



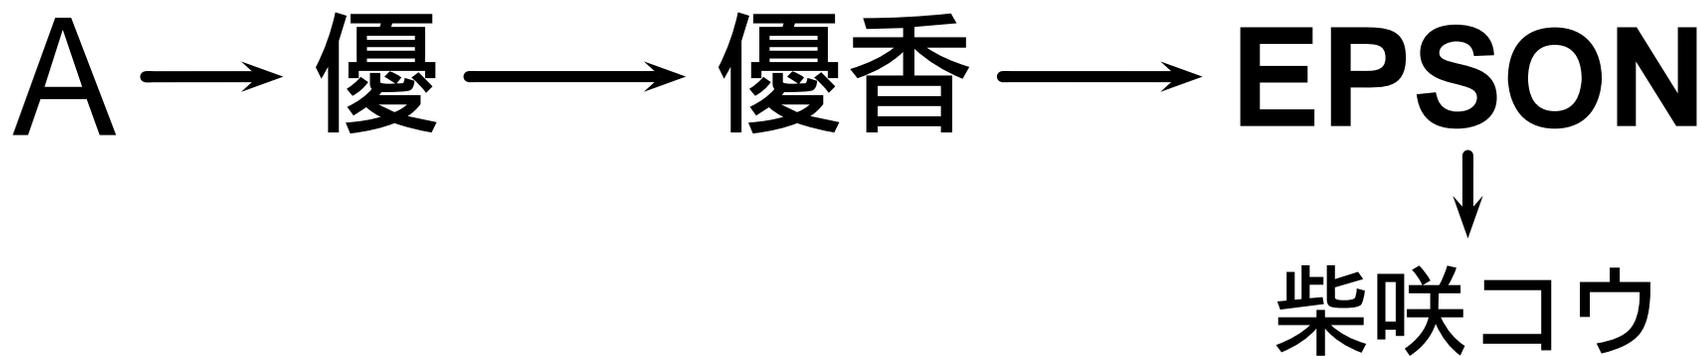
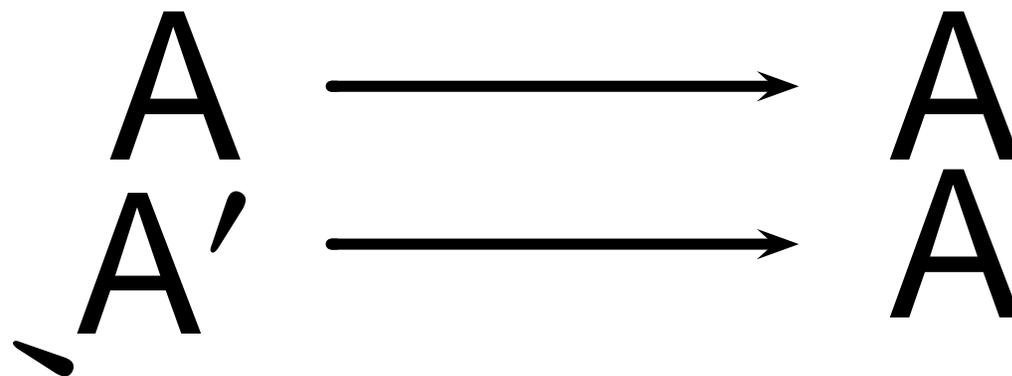
A → 優 → 優香

# もっと動的な連想記憶

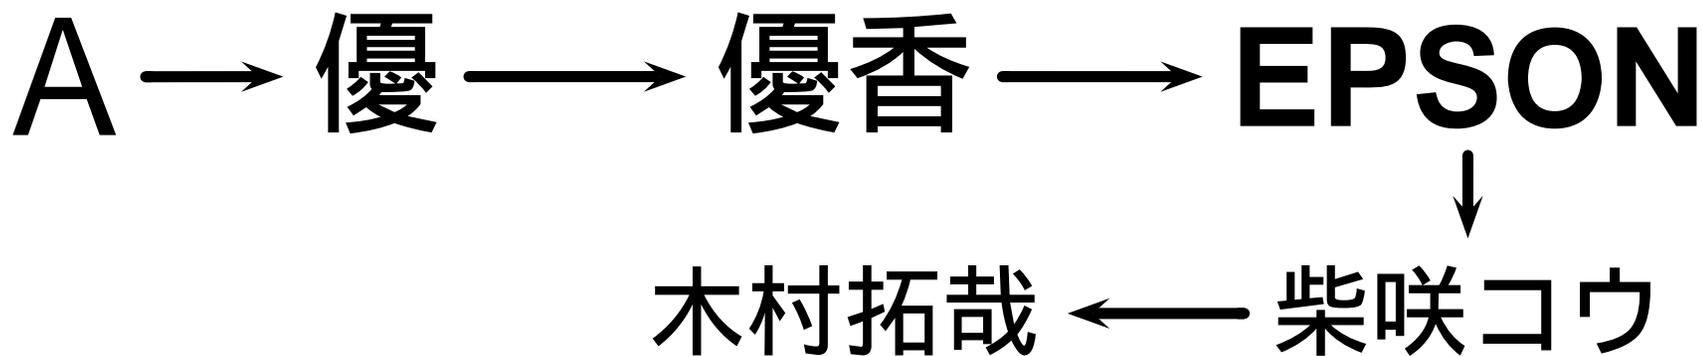
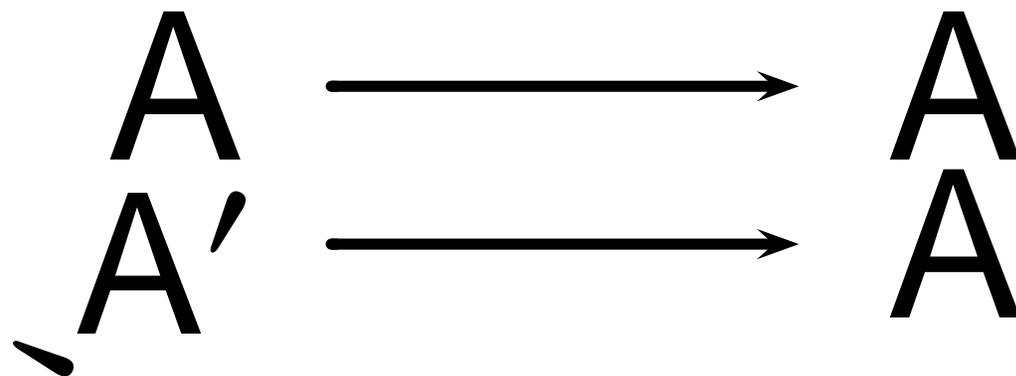


A → 優 → 優香 → EPSON

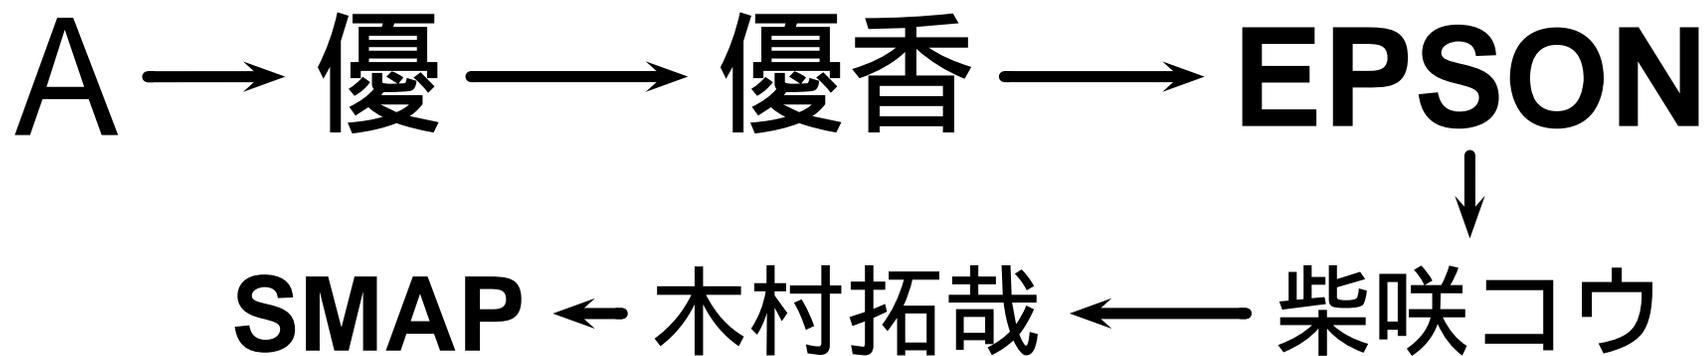
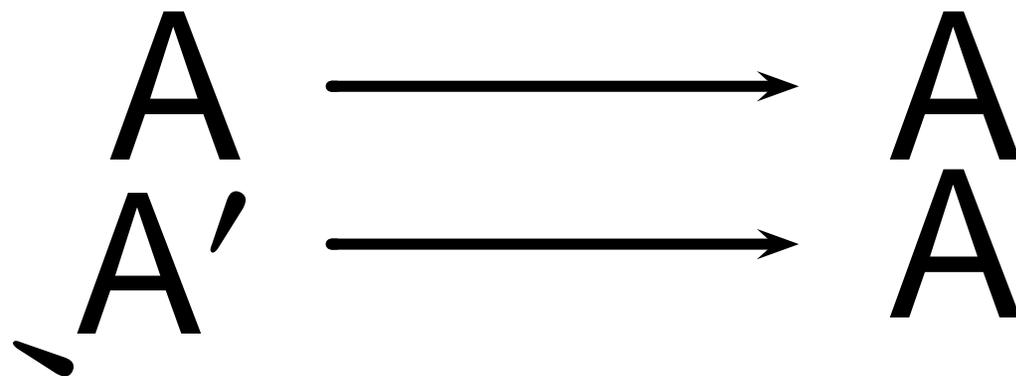
# もっと動的な連想記憶



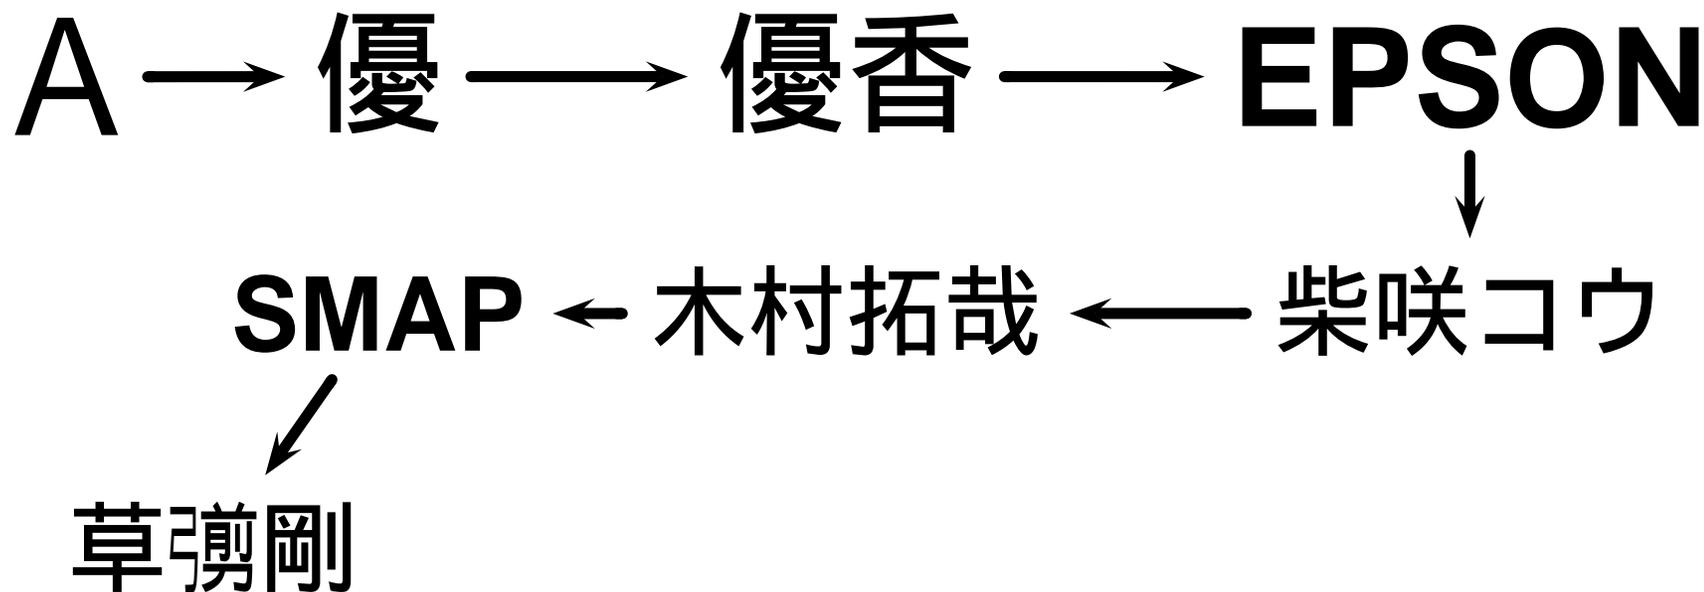
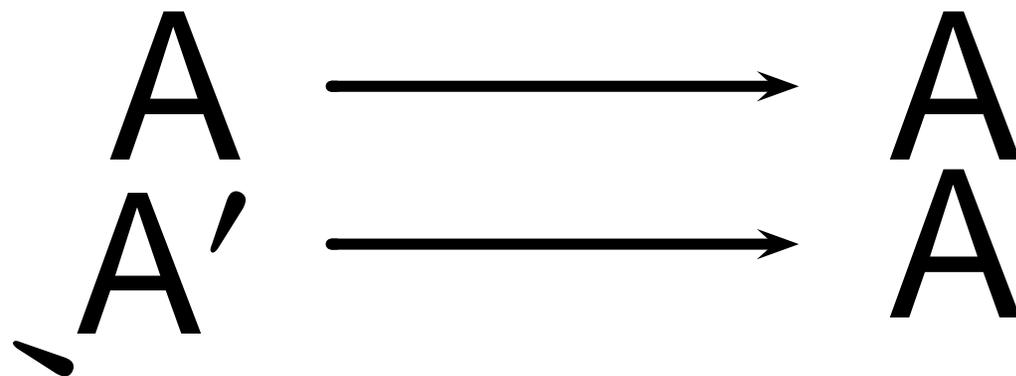
# もっと動的な連想記憶



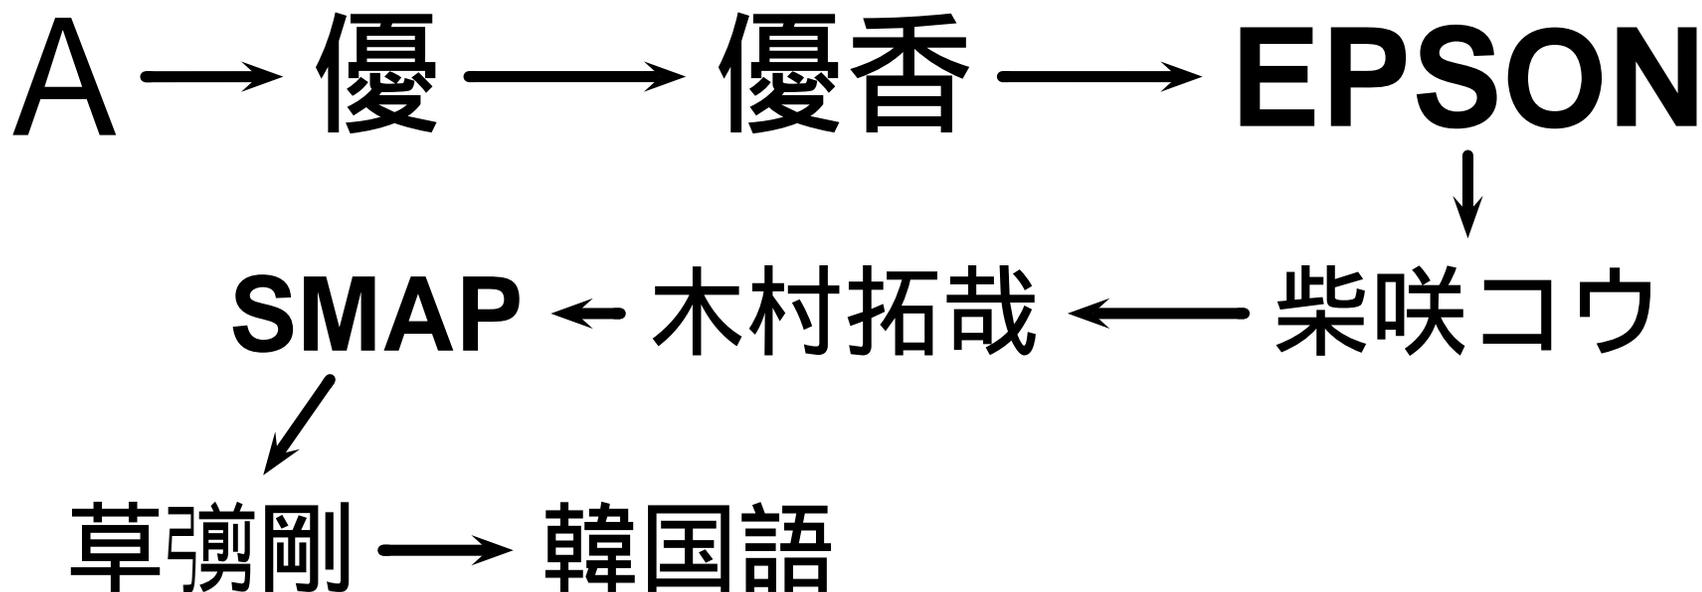
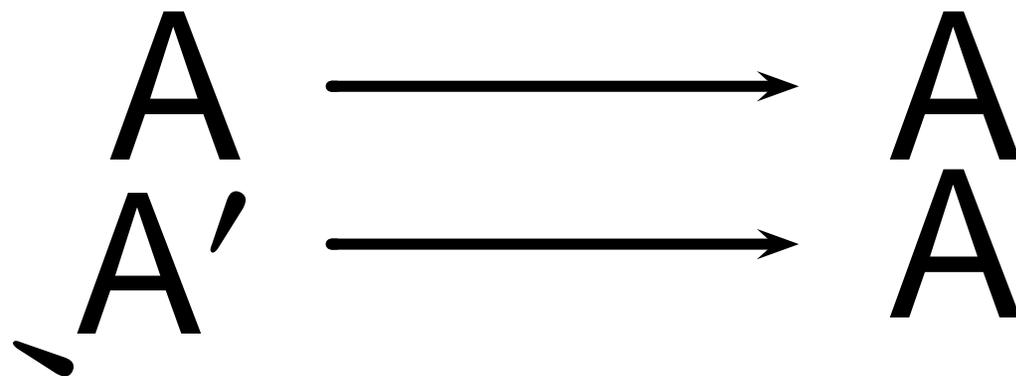
# もっと動的な連想記憶



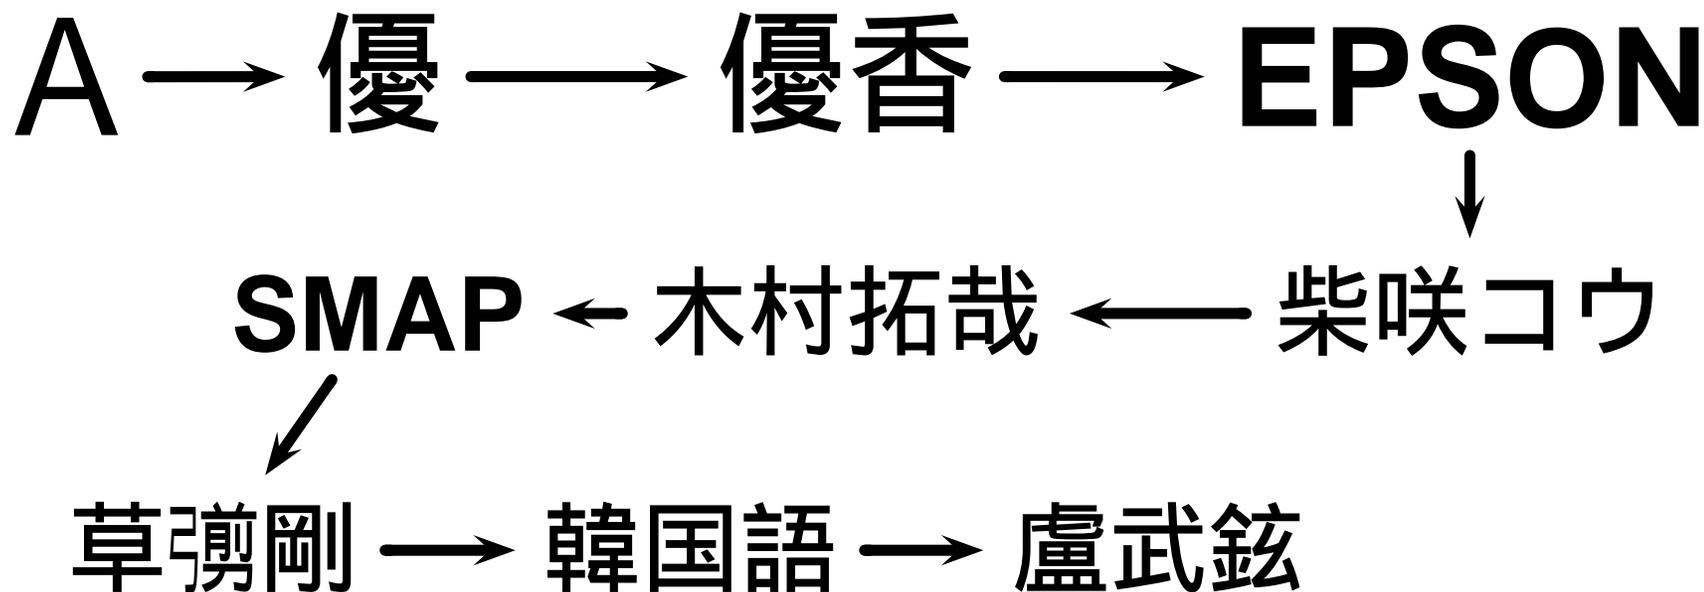
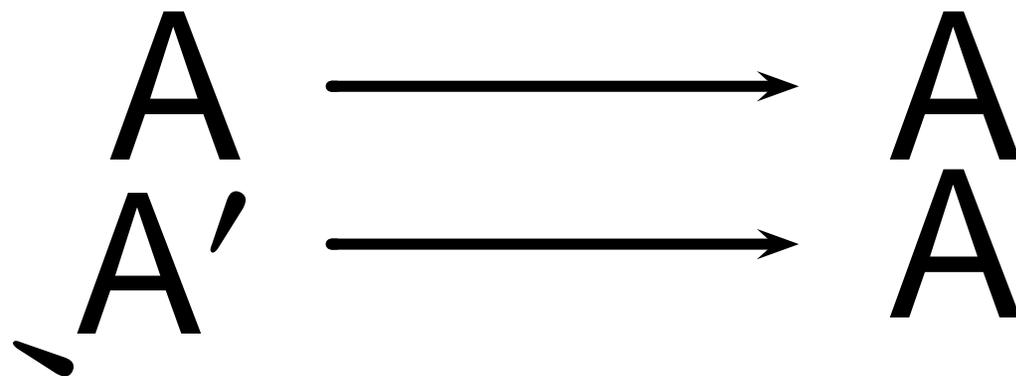
# もっと動的な連想記憶



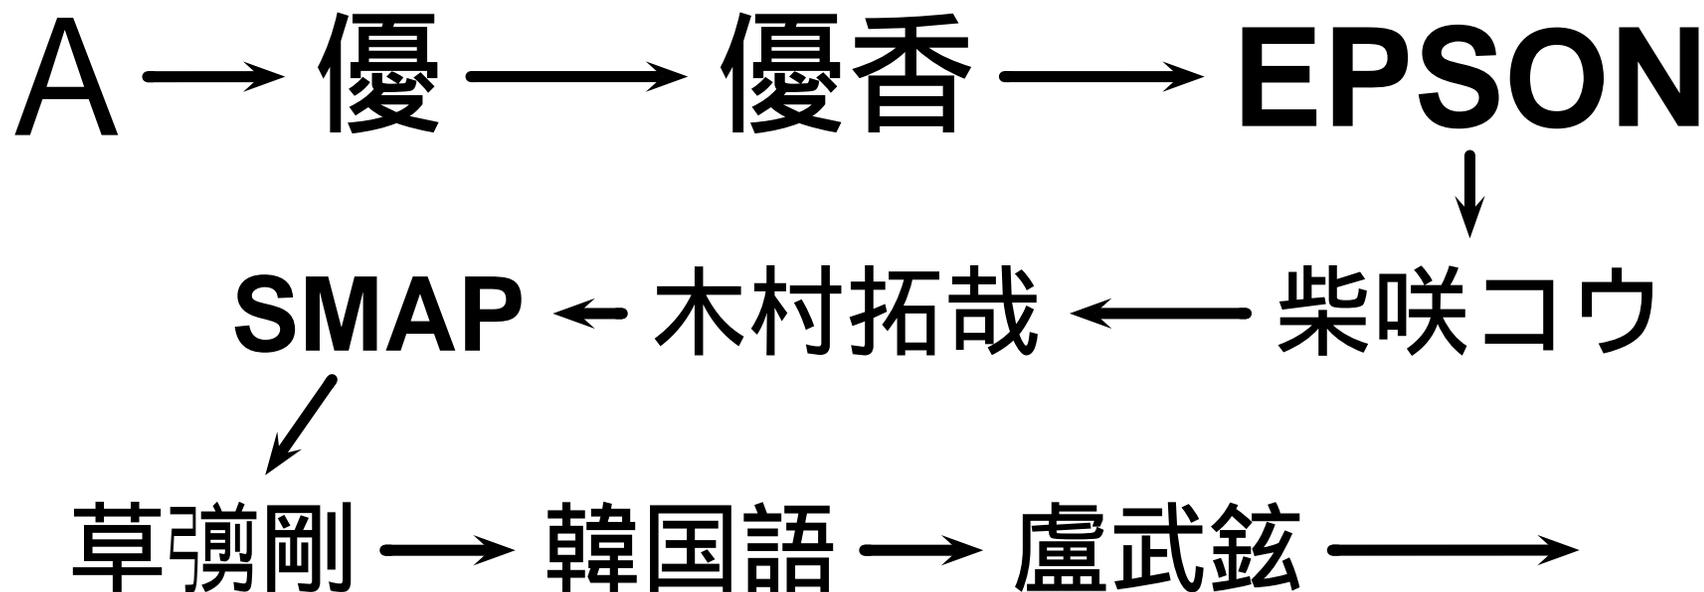
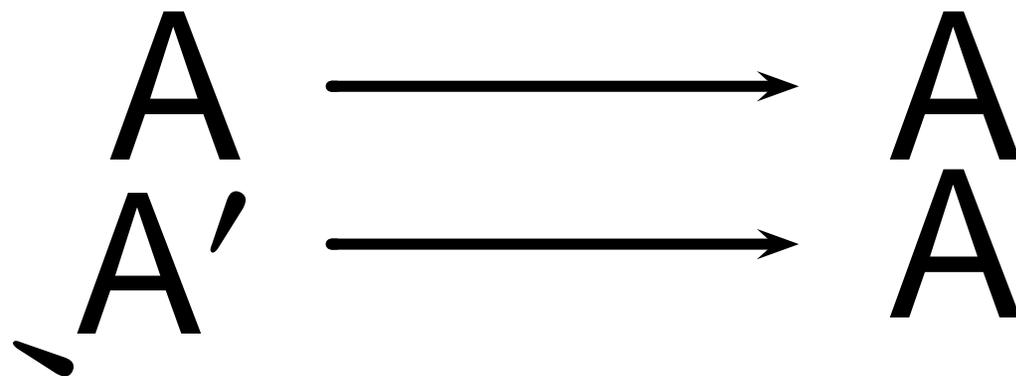
# もっと動的な連想記憶



# もっと動的な連想記憶



# もっと動的な連想記憶



# CNNによる動的連想記憶

- ◀ カオスニューラルネットワーク
- ◀ 結合係数  $W_{ij}$  を相関行列で決定
- ◀ リアプノフ指数などで、ダイナミクスを評価
- ◀ カオス的遍歴現象の観測

# カオスニューラルネットワークの応用

## ◀ 連想記憶

- 動的な連想記憶
- カオスの遍歴

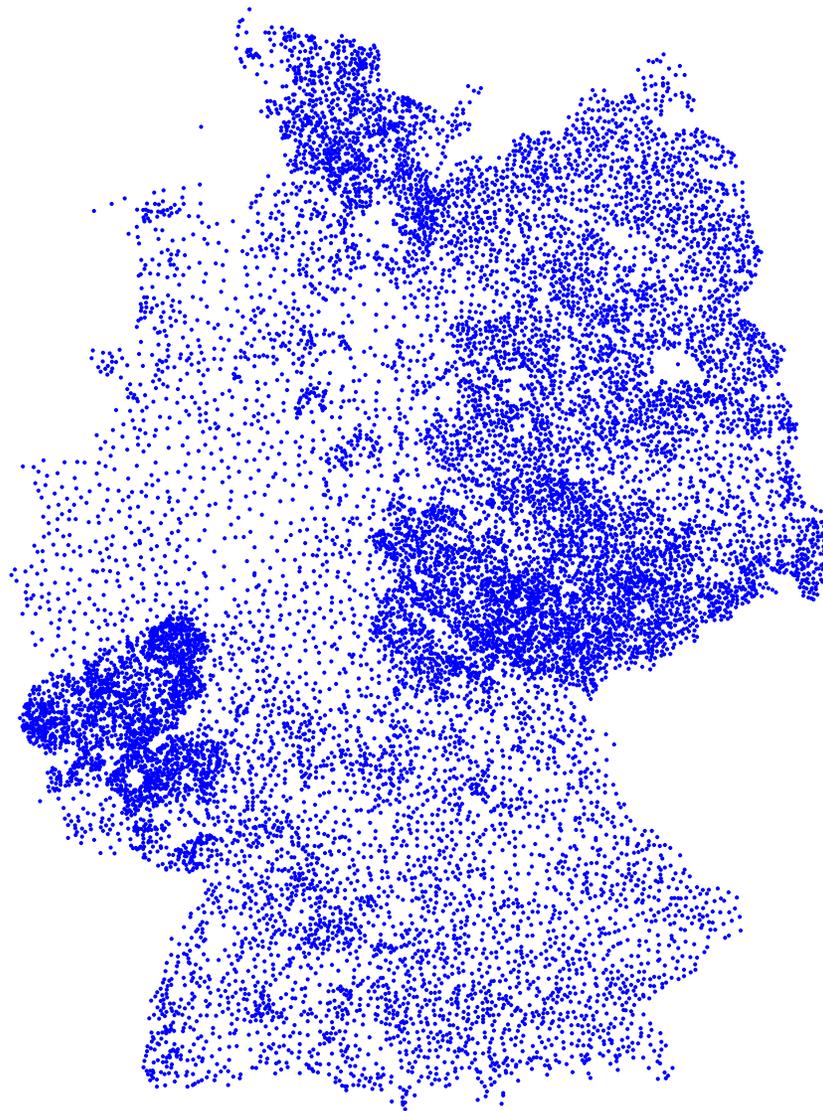
## ◀ 組み合わせ最適化問題

- 巡回セールスマン問題 (TSP)
- 2次割り当て問題 (QAP)

# 巡回セールスマン問題 (TSP)

あるセールスマンが、 $N$  都市を巡回して旅行することになった。各都市間の距離が与えられたとして、これらの  $N$  都市を一度だけ訪れ、最後に出発点となる都市に戻るような経路 (巡回路) の中で最も短いものを求めよ。

# TSP (d15112)



# URLs

## ◀ TSPLIB

<http://www.iwr.euni-heidelberg.de/groups/comopt/software/TSPLIB95/>

## ◀ TSPBIB

[http://www.densis.fee.unicamp.br/~moscato/TSPBIB\\_home.html](http://www.densis.fee.unicamp.br/~moscato/TSPBIB_home.html)

## ◀ Solving Travelling Salesman Problem

<http://www.math.princeton.edu/tsp/>

# 巡回セールスマン問題 (TSP)

あるセールスマンが、 $N$  都市を巡回して旅行することになった。各都市間の距離が与えられたとして、これらの  $N$  都市を一度だけ訪れ、最後に出発点となる都市に戻るような経路 (巡回路) の中で最も短いものを求めよ。

# 巡回セールスマン問題 (TSP)

あるセールスマンが、 $N$  都市を巡回して旅行することになった。各都市間の距離が与えられたとして、これらの  $N$  都市を一度だけ訪れ、最後に出発点となる都市に戻るような経路 (巡回路) の中で最も短いものを求めよ。



◀ 最初に思いつきそうな解法は？

- ❑ 全ての巡回路の長さを出す。
- ❑ 最も短い巡回路長を与える訪問順を解とする。

# 巡回セールスマン問題 (TSP)

あるセールスマンが、 $N$  都市を巡回して旅行することになった。各都市間の距離が与えられたとして、これらの  $N$  都市を一度だけ訪れ、最後に出発点となる都市に戻るような経路 (巡回路) の中で最も短いものを求めよ。

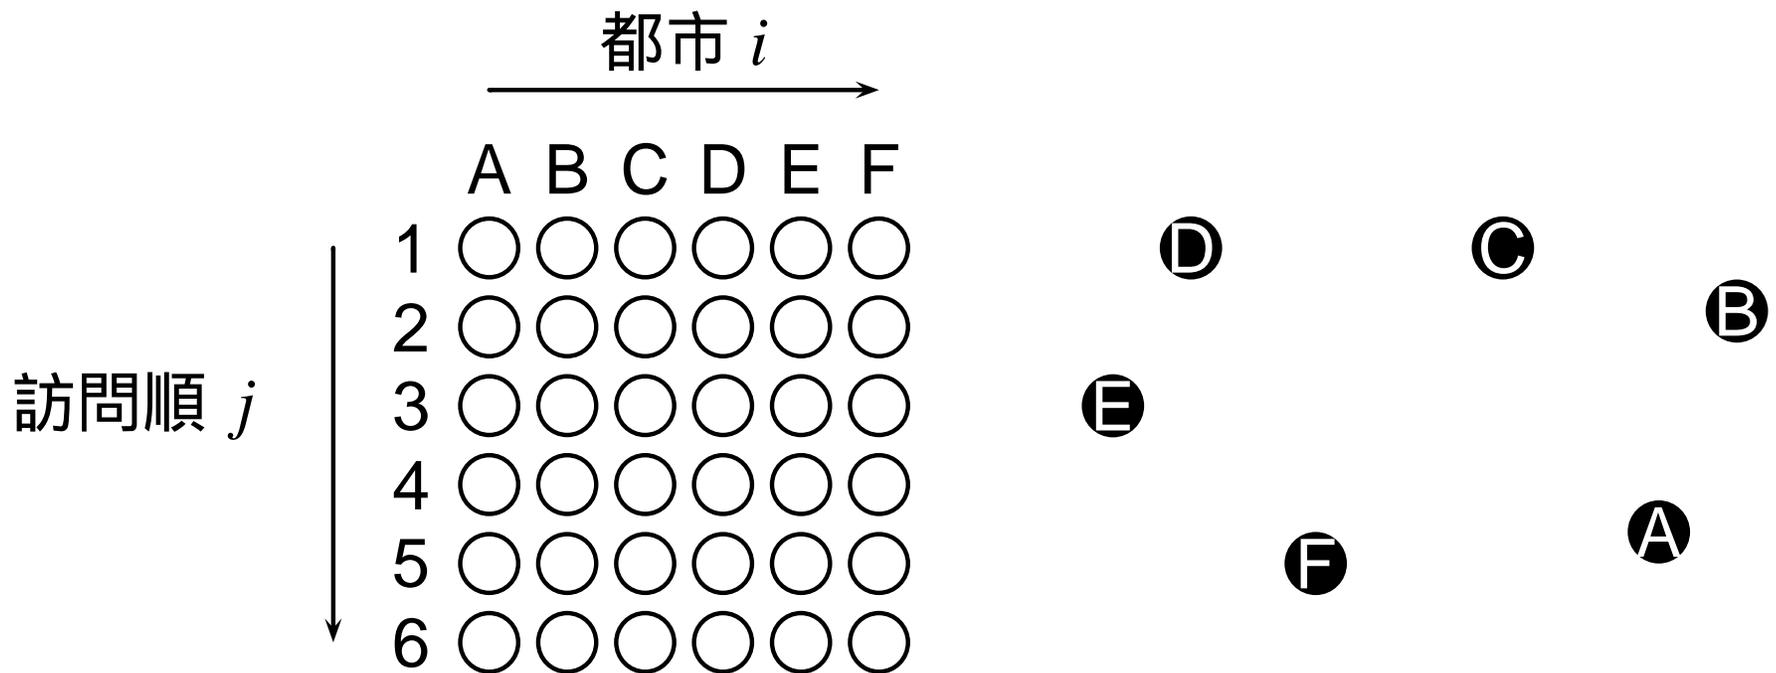


- ◀ 最初に思いつきそうな解法は?
  - 全ての巡回路の長さを出す。
  - 最も短い巡回路長を与える訪問順を解とする。
- ◀ 全く実用的でない。
  - ∴ 巡回路の総数は  $(N - 1)!/2$
  - ⇒  $N$  の増加とともに指数関数的に増大



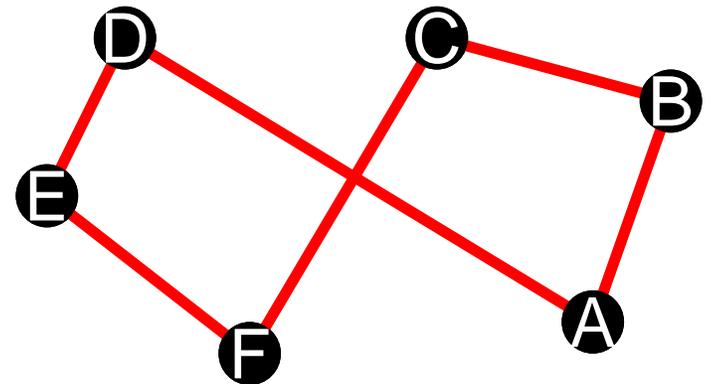
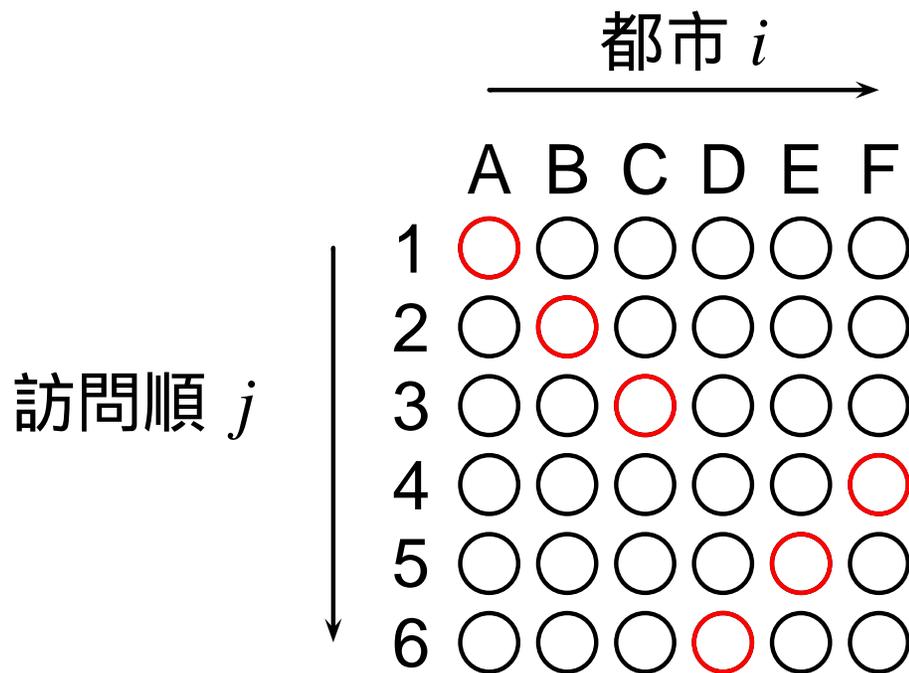
# 相互結合型ニューラルネットによる TSP の解法

- ◀  $N$ -都市 TSP  $\Rightarrow N \times N$  のニューロンを用意
- ◀  $(i, j)$  ニューロンの発火  $\Leftrightarrow$  都市  $i$  を  $j$  番目に訪問する経路



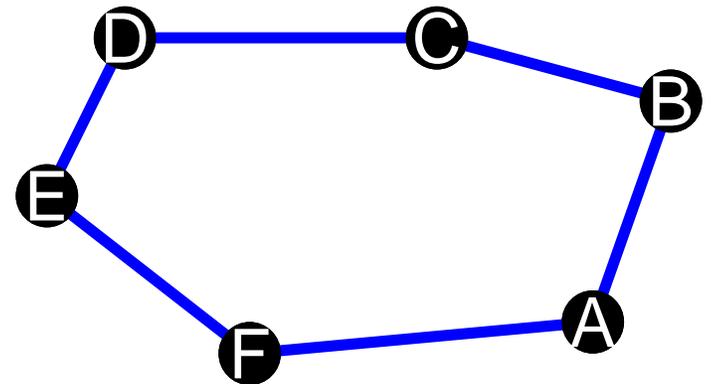
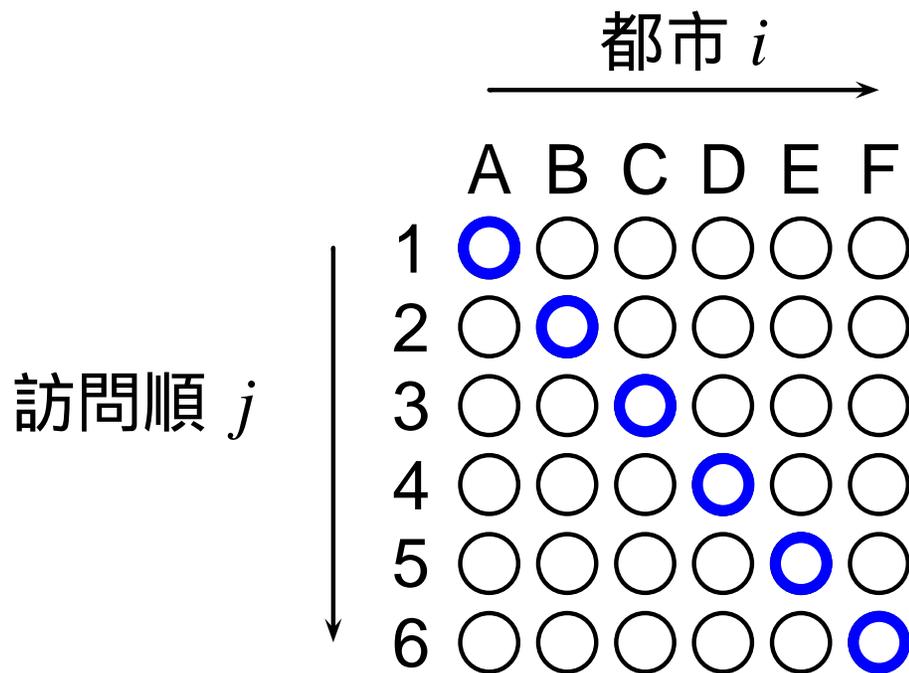
# 相互結合型ニューラルネットによる TSP の解法

- ◀  $N$ -都市 TSP  $\Rightarrow N \times N$  のニューロンを用意
- ◀  $(i, j)$  ニューロンの発火  $\Leftrightarrow$  都市  $i$  を  $j$  番目に訪問する経路



# 相互結合型ニューラルネットによる TSP の解法

- ◀  $N$ -都市 TSP  $\Rightarrow N \times N$  のニューロンを用意
- ◀  $(i, j)$  ニューロンの発火  $\Leftrightarrow$  都市  $i$  を  $j$  番目に訪問する経路



# TSP と制約条件

- ◀  $N$  都市問題に対して  $N \times N$  個のニューロンを用意する。
  - 各行, 各列において, 発火しているニューロン数は 1 となるような発火パターンが必要.
  - もちろん, 巡回路長 (距離) は短くする必要がある.
- ◀ ある行  $i$  に着目すると

$$E_1 = \sum_i \left( \sum_j x_{ij} - 1 \right)^2$$

- ◀ ある列  $j$  に着目すると

$$E_2 = \sum_j \left( \sum_i x_{ij} - 1 \right)^2$$

# TSP と制約条件

$$E_1 = \sum_i \left( \sum_j x_{ij} - 1 \right)^2$$

$$E_2 = \sum_j \left( \sum_i x_{ij} - 1 \right)^2$$

$$E_3 = \sum_i \sum_j \sum_m d_{im} x_{ij} (x_{mj+1} x_{mj-1})$$

$$E = A(E_1 + E_2) + BE_3$$

# 展開

$$E_1 = \sum_i \left( \sum_j x_{ij} - 1 \right)^2 = \sum_i \left\{ \left( \sum_j x_{ij} \right)^2 - 2 \sum_j x_{ij} + 1 \right\}$$

$$= \sum_i \left\{ \sum_j x_{ij} \sum_n x_{in} - 2 \sum_j x_{ij} + 1 \right\}$$

$$= \sum_i \left\{ \sum_j \sum_n x_{ij} x_{in} - 2 \sum_j x_{ij} + 1 \right\}$$

1 =  $(1 - \delta_{jn}) + \delta_{jn}$  を用いると ,

$$= \sum_i \left\{ \sum_j \sum_n (1 - \delta_{jn}) x_{ij} x_{in} + \sum_j \sum_n \delta_{jn} x_{ij} x_{in} - 2 \sum_j x_{ij} + 1 \right\}$$

また

$$\sum_j \sum_n \delta_{jn} x_{ij} x_{in} = \sum_j \delta_{jj} x_{ij}^2 = \sum_j \delta_{jj} x_{ij} = \sum_j x_{ij}$$

であるので、

$$\begin{aligned} E_1 &= \sum_i \left\{ \sum_j \sum_n (1 - \delta_{jn}) x_{ij} x_{in} + \sum_j \sum_n \delta_{jn} x_{ij} x_{in} - 2 \sum_j x_{ij} + 1 \right\} \\ &= \sum_i \left\{ \sum_j \sum_n (1 - \delta_{jn}) x_{ij} x_{in} - \sum_j x_{ij} + 1 \right\} \\ &= \sum_i \sum_j \sum_n (1 - \delta_{jn}) x_{ij} x_{in} - \sum_i \sum_j x_{ij} + \sum_i 1 \end{aligned}$$

さて，以下の式において， $m = i$  のときのみ

$$\sum_m \delta_{im} = \delta_{ii} = 1$$

となるので，

$$\begin{aligned} E_1 &= \sum_i \sum_j \sum_n (1 - \delta_{jn}) x_{ij} x_{in} - \sum_i \sum_j x_{ij} + \sum_i 1 \\ &= \sum_i \left( \sum_m \delta_{im} \right) \sum_j \sum_n (1 - \delta_{jn}) x_{ij} x_{in} - \sum_i \sum_j x_{ij} + \sum_i 1 \\ &= \sum_i \sum_m \sum_j \sum_n \delta_{im} (1 - \delta_{jn}) x_{ij} x_{in} - \sum_i \sum_j x_{ij} + \sum_i 1 \end{aligned}$$

同様にして

$$E_2 = \sum_j \sum_n \sum_i \sum_m \delta_{jn}(1 - \delta_{im})x_{ij}x_{in} - \sum_i \sum_j x_{ij} + \sum_i 1$$

従って、「各行各列の発火ニューロン数が1個である」という制約条件は、

$$E_1 + E_2 = \sum_i \sum_m \sum_j \sum_n \left[ \delta_{im}(1 - \delta_{jn}) + \delta_{jn}(1 - \delta_{im}) \right] x_{ij}x_{mn}$$

また、距離を最小とする制約条件により、

$$E_3 = \sum_i \sum_j \sum_m \sum_n d_{im}(\delta_{j+1n} + \delta_{j-1n})x_{ij}x_{mn}$$

# 結合係数の決定

◀ まとめると ,

$$W_{ijmn} = -2A \left\{ \delta_{im}(1 - \delta_{jn}) + \delta_{jn}(1 - \delta_{im}) - B d_{im}(\delta_{j+1n} + \delta_{j-1n}) \right\}$$
$$\theta_{ij} = A$$

とすれば良い .

◀ エネルギー最小化原理により , 上のように結合係数を決めてやれば , 与えられた初期値からスタートして , エネルギー

$$A(E_1 + E_2) + BE_3$$

を小さくするように , ネットワークは動作する .

◀ Hopfield & Tank (1985) がエネルギー最小化するニューラルネットのダイナミクスを用いて , TSP 等へ応用