

# Generative Topographic Mapping GTM

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

# GTM とは？

- ✓ データを可視化・見える化するための非線形手法
- ✓ 主成分分析などとは異なり、はじめに二次元平面の座標を作ってしまう、それを実際の多次元空間のサンプルに合わせて込むというスタンス
- ✓ ゴム状のシート（二次元平面）を曲げたり伸び縮みさせたりしながら、多次元空間にあるサンプルを通るようにシートを置き、そのシートにサンプルを射影するような手法
- ✓ 自己組織化マップ（Self-Organizing Map, SOM）のいろいろな問題点を解決した、上位互換の手法
- ✓ ハイパーパラメータの数が多いため、設定の際には注意が必要
- ✓ 2次元平面において近いところにあるサンプル同士は、多次元空間においても近い

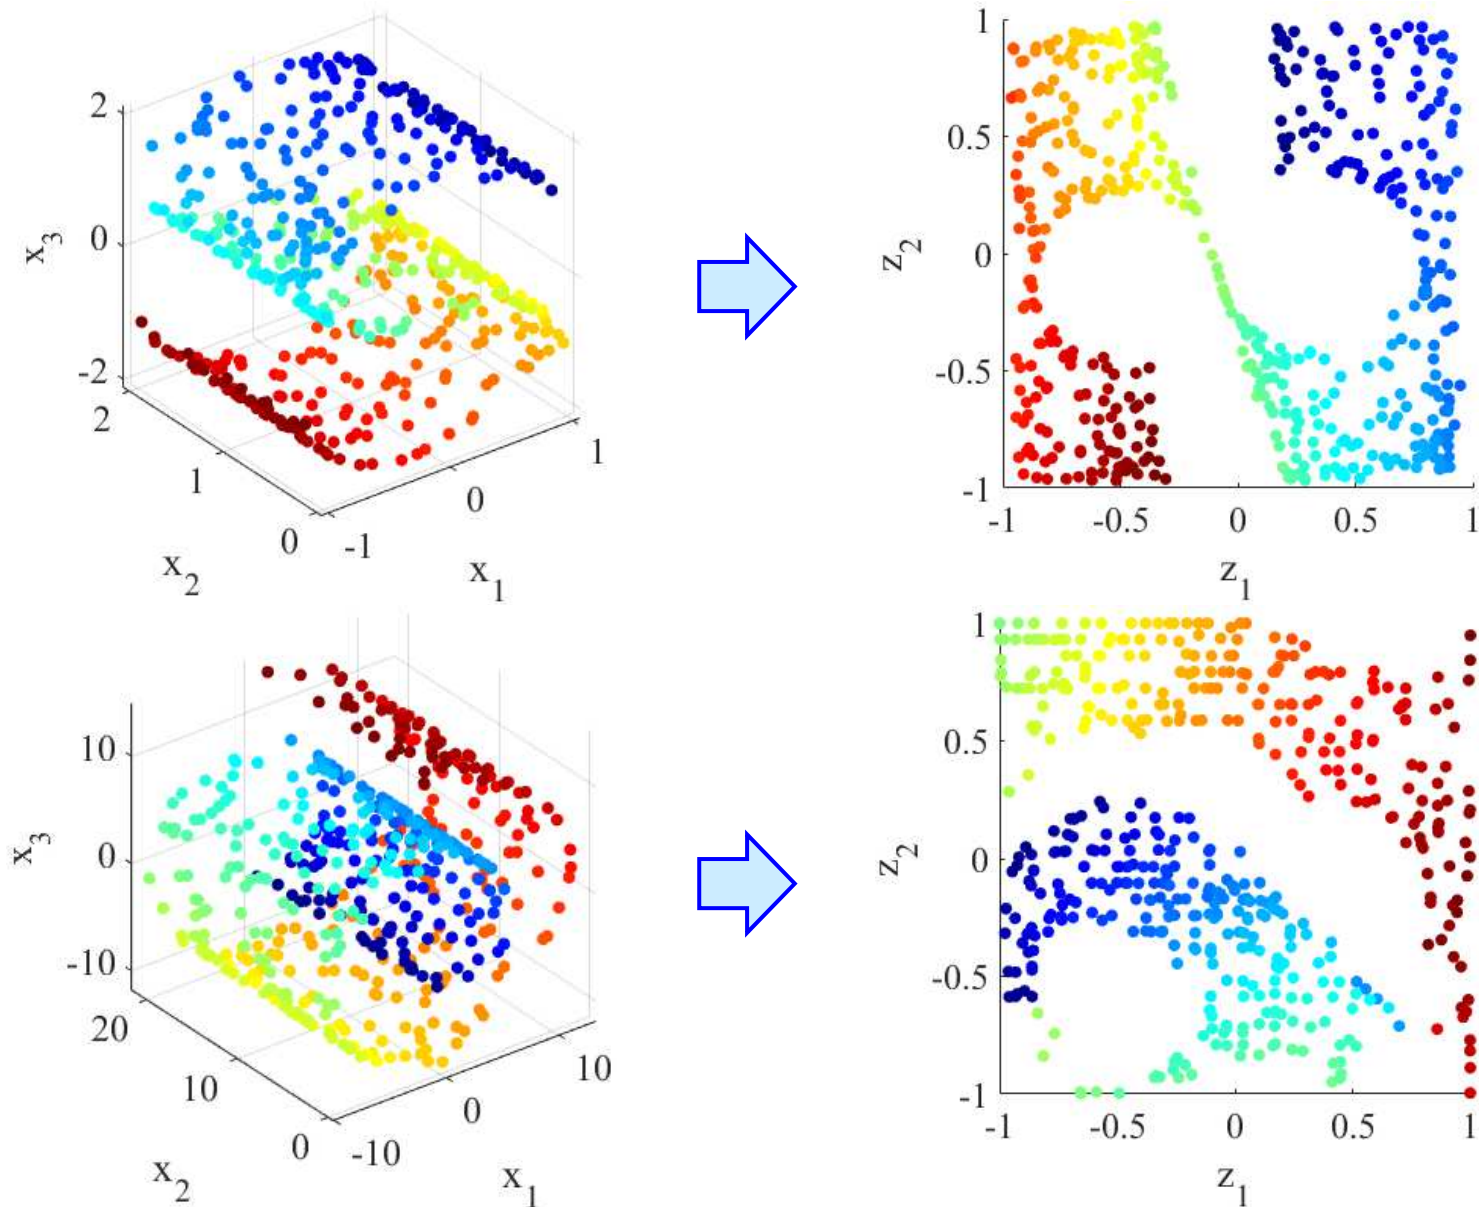
# GTMで解決できたSOMの問題点

- ✓元の多次元空間においてサンプル同士が似ているからといって、SOMの2次元平面上でも似ているとは限らない
- ✓二次元平面への可視化結果の良し悪しを評価するための関数(評価関数 or コスト関数)がない
- ✓学習回数を大きくしたとしても、計算が収束するとは限らない
- ✓二次元平面への可視化結果として、SOMにおいて発火したニューロンのどれか、だけあり確率で表わされるわけではない
- ✓学習率や近傍関数をどのように設定すればよいかわからない

# GTMの大まかな流れ

- ✓① 二次元平面のサイズを決める
  - $10 \times 10$ とか、 $20 \times 20$ とか
- ✓② 二次元平面から多次元空間へ変換する関数を決める
- ✓③ 多次元空間におけるデータセットになるべく当てはまるように②の関数のパラメータを最適化する
- ✓④ サンプルごとの、二次元平面上の各グリッド (格子点) に存在する確率を求める
- ✓⑤ 確率から、二次元平面上の位置を決める

# GTMによる可視化の例



# こんなデータセットがあるとする

		変数						
		1	2	...	$i$	...	$m-1$	$m$
サンプル	1							
	2							
	⋮							
	$j$				$x_i^{(j)}$			
	⋮							
	$n-1$							
$n$								

# 1つのサンプル、全サンプル

✓ 1つのサンプルを  $\mathbf{x}^{(i)}$ 、

✓ 全サンプルを  $\mathbf{X}$

とする

# GTMを誤解なく理解するための発想の転換


- ✓ GTMは一見、多次元 (m次元) → 2次元 の低次元化手法と  
思われがち
- ✓ 発想を転換して、多次元 (m次元) → [グリッド数] 次元 への  
変換手法と考えたほうが、GTMを理解しやすい
  - たとえば、二次元平面のサイズが  $10 \times 10$  のとき、  
[グリッド数] = 100



# ① 二次元平面のサイズを決める

- ✓ 縦のサイズと横のサイズは同じにすることが多い
  - $k \times k$  とする
- ✓ 縦も横も、-1 から 1 の間でグリッド (格子点) を決める
- ✓  $k$  を大きめに設定したとしても、計算時間が多めにかかるだけで、オーバーフィッティングへの影響はほとんどない
  - のちに設定する基底関数の数のほうが、オーバーフィッティングへの関係が強い

# ① 二次元平面



# ① グリッド (格子点) の座標

✓グリッド (格子点) の座標を

$$\mathbf{Z} = \begin{bmatrix} z_1^{(1)} & z_2^{(1)} \\ \vdots & \vdots \\ z_1^{(j)} & z_2^{(j)} \\ \vdots & \vdots \\ z_1^{(k^2)} & z_2^{(k^2)} \end{bmatrix} \quad \text{とする}$$

✓また、 $\mathbf{z}^{(j)} = \begin{bmatrix} z_1^{(j)} & z_2^{(j)} \end{bmatrix}$  とする

## ② 二次元 → 多次元 の変換

✓ 二次元から多次元へ変換する非線形関数を  $f$  とする

$$\mathbf{x}^{(i)} = f(\mathbf{z}^{(j)})$$

## ② 基底関数


✓  $f$  を、 $p$  個の基底関数という非線形関数の線形結合とする

✓  $i$  番目の基底関数  $\phi_i(\mathbf{z}^{(j)})$  は、二次元平面上における、中心  $\mathbf{t}^{(i)} = [t_1^{(i)} \ t_2^{(i)}]$  から同心円状に値が小さくなる、以下の放射基底関数 (radial basis function)

$$\phi_i(\mathbf{z}^{(j)}) = \exp \left\{ -\frac{1}{2\sigma^2} \left\| \mathbf{t}^{(i)} - \mathbf{z}^{(j)} \right\|^2 \right\}$$

✓  $p = q \times q$  として、基底関数の中心を二次元平面上にまんべんなく置くことが多い

## ② 基底関数の中心の配置



## ② 重み $\mathbf{W}$

✓  $f$  を、 $p$  個の基底関数という非線形関数の線形結合とする

$$\begin{aligned} f(\mathbf{z}^{(j)}) &= \phi_1(\mathbf{z}^{(j)}) \mathbf{w}_1 + \phi_2(\mathbf{z}^{(j)}) \mathbf{w}_2 + \cdots + \phi_{q^2}(\mathbf{z}^{(j)}) \mathbf{w}_{q^2} \\ &= \Phi(\mathbf{z}^{(j)}) \mathbf{W} \end{aligned}$$

✓ ただし、

$$\mathbf{w}_i = \begin{bmatrix} w_i^{(1)} & w_i^{(2)} & \cdots & w_i^{(m)} \end{bmatrix}$$

$$\mathbf{W} = \begin{bmatrix} \mathbf{w}_1^T & \mathbf{w}_2^T & \cdots & \mathbf{w}_{q^2}^T \end{bmatrix}^T$$

$$\Phi(\mathbf{z}^{(j)}) = \begin{bmatrix} \phi_1(\mathbf{z}^{(j)}) & \phi_2(\mathbf{z}^{(j)}) & \cdots & \phi_{q^2}(\mathbf{z}^{(j)}) \end{bmatrix}$$

## ② 二次元→多次元 の変換は分布をもつ

✓二次元平面の各グリッドから、多次元空間への変換は、  
 $f(\mathbf{z}^{(j)}) = \Phi(\mathbf{z}^{(j)})\mathbf{W}$  を中心とした正規分布

$$p(\mathbf{x} | \mathbf{z}^{(j)}, \mathbf{W}, \beta) = \left(\frac{\beta}{2\pi}\right)^{\frac{m}{2}} \exp\left\{-\frac{\beta}{2}\|\Phi(\mathbf{z}^{(j)})\mathbf{W} - \mathbf{x}\|^2\right\}$$



$\beta$  : 正規分布の分散の逆数

$\mathbf{W}$ 、 $\beta$  が決まったあとに、 $\mathbf{z}^{(j)}$  を入力したときの多次元空間における  
確率分布 (probability distribution) という意味

✓確率分布なので、値をすべて足すと 1 になる



## ② すべてのグリッド(格子点)からの変換

- ✓ 二次元平面におけるすべてのグリッドを多次元空間に変換する
- ✓ 多次元空間における確率分布  $p(\mathbf{x} | \mathbf{W}, \beta)$  は、各グリッドにおける  $p(\mathbf{x} | \mathbf{z}^{(j)}, \mathbf{W}, \beta)$  をすべてのグリッドで足し合わせ、最後にグリッド数で割ることで与えられる
  - グリッド数で割るのは、足して 1 にするため

$$p(\mathbf{x} | \mathbf{W}, \beta) = \frac{1}{k^2} \sum_{j=1}^{k^2} p(\mathbf{x} | \mathbf{z}^{(j)}, \mathbf{W}, \beta)$$

### ③ 最適化のための準備

✓ 確率分布  $p(\mathbf{x} | \mathbf{W}, \beta)$  が、多次元空間における実際のデータ分布を表現していればよい

✓ つまり、各サンプル  $\mathbf{x}^{(i)}$  の確率  $p(\mathbf{x}^{(i)} | \mathbf{W}, \beta)$  をすべてのサンプルで  
かけあわせたものが、大きければよい



$$\prod_{i=1}^n p(\mathbf{x}^{(i)} | \mathbf{W}, \beta)$$

### ③ 尤度関数 $L$

✓  $\prod_{i=1}^n p(\mathbf{x}^{(i)} | \mathbf{W}, \beta)$  について、対数をとったものを尤度関数  $L$  とする

✓  $L$  は  $\mathbf{W}$  と  $\beta$  の関数

$$\begin{aligned} L(\mathbf{W}, \beta) &= \sum_{i=1}^n \ln \left\{ p(\mathbf{x}^{(i)} | \mathbf{W}, \beta) \right\} \\ &= \sum_{i=1}^n \ln \left\{ \frac{1}{k^2} \sum_{j=1}^{k^2} p(\mathbf{x}^{(i)} | \mathbf{z}^{(j)}, \mathbf{W}, \beta) \right\} \\ &= \sum_{i=1}^n \ln \left\{ \frac{1}{k^2} \left( \frac{\beta}{2\pi} \right)^{\frac{m}{2}} \sum_{j=1}^{k^2} \exp \left\{ -\frac{\beta}{2} \left\| \Phi(\mathbf{z}^{(j)}) \mathbf{W} - \mathbf{x}^{(i)} \right\|^2 \right\} \right\} \end{aligned}$$

✓  $L$  の最大化を試みる

### ③ EMアルゴリズム

- ✓ 一般的には、 $L$  を  $\mathbf{W}$  と  $\beta$  で微分して、勾配法・ニュートン法などで  $L$  を最大化し、そのときの  $\mathbf{W}$  や  $\beta$  を求める
  
- ✓ 今回は微分が難しい
  
- ✓  $L$  の最大化を、 $\mathbf{W}$  と  $\beta$  が不明という不完全データ問題としてとらえ、EM (Expectation–Maximization) アルゴリズムを用いて  $L$  が最大となる  $\mathbf{W}$  と  $\beta$  を求める
  - EステップとMステップとを繰り返して  $\mathbf{W}$  と  $\beta$  を求める
    - Eステップ：今の  $\mathbf{W}$  と  $\beta$  のもとで、尤度関数の条件付き確率に関する期待値を計算
    - Mステップ：期待値を最大化する  $\mathbf{W}$  と  $\beta$  を計算

EMアルゴリズム

<https://ja.wikipedia.org/wiki/EM%E3%82%A2%E3%83%AB%E3%82%B4%E3%83%AA%E3%82%BA%E3%83%A0>

### ③ Responsibility (R)

#### ✓ Responsibility

- あるサンプル  $\mathbf{x}^{(i)}$  に対応する あるグリッド  $\mathbf{z}^{(j)}$  の確率
- Eステップにおける条件付き確率
  - ベイズの定理により計算

$$\begin{aligned} R_{\mathbf{x}^{(i)}, \mathbf{z}^{(j)}}(\mathbf{W}, \beta) &= p(\mathbf{z}^{(j)} | \mathbf{x}^{(i)}, \mathbf{W}, \beta) \\ &= \frac{p(\mathbf{x}^{(i)} | \mathbf{z}^{(j)}, \mathbf{W}, \beta)}{\sum_{r=1}^{k^2} p(\mathbf{x}^{(i)} | \mathbf{z}^{(r)}, \mathbf{W}, \beta)} \end{aligned}$$

### ③ Mステップで最大化する関数 $L_{\text{comp}}$

✓EMアルゴリズムにおいて繰り返し計算  $a$  回目の  $\mathbf{W}, \beta$  をそれぞれ  $\mathbf{W}_a, \beta_a$  とする

$$R_{\mathbf{x}^{(i)}, \mathbf{z}^{(j)}}(\mathbf{W}_a, \beta_a) = \frac{p(\mathbf{x}^{(i)} | \mathbf{z}^{(j)}, \mathbf{W}_a, \beta_a)}{\sum_{r=1}^{k^2} p(\mathbf{x}^{(i)} | \mathbf{z}^{(r)}, \mathbf{W}_a, \beta_a)}$$

✓Mステップにおいて、 $\mathbf{W}, \beta$  について最大化する関数  $L_{\text{comp}}(\mathbf{W}, \beta)$  は、

$$L_{\text{comp}}(\mathbf{W}, \beta) = \sum_{i=1}^n \sum_{j=1}^{k^2} R_{\mathbf{x}^{(i)}, \mathbf{z}^{(j)}}(\mathbf{W}_a, \beta_a) \ln \left\{ p(\mathbf{x}^{(i)} | \mathbf{z}^{(j)}, \mathbf{W}, \beta) \right\}$$

### ③ $L_{\text{comp}}$ を最大化させる $W$

✓  $L_{\text{comp}}(W, \beta)$ を  $W$  で微分して、0とする

✓ そのときの  $W$  を  $W_{a+1}$  とする

$$\sum_{i=1}^n \sum_{j=1}^{k^2} R_{\mathbf{x}^{(i)}, \mathbf{z}^{(j)}}(W_a, \beta_a) \left\{ \Phi(\mathbf{z}^{(j)}) W_{a+1} - \mathbf{x}^{(i)} \right\} \Phi^T(\mathbf{z}^{(j)}) = 0$$

✓ これを満たす  $W_{a+1}$  を計算

### ③ $L_{\text{comp}}$ を最大化させる $\beta$

✓  $L_{\text{comp}}(\mathbf{W}, \beta)$  を  $\beta$  で微分して、0 とする

✓ そのときの  $\beta$  を  $\beta_{a+1}$  とする

$$\frac{1}{\beta_{a+1}} = \frac{1}{mn} \sum_{i=1}^n \sum_{j=1}^{k^2} R_{\mathbf{x}^{(i)}, \mathbf{z}^{(j)}}(\mathbf{W}_a, \beta_a) \left\| \Phi(\mathbf{z}^{(j)}) \mathbf{W}_{a+1} - \mathbf{x}^{(i)} \right\|^2$$

✓ これを満たす  $\beta_{a+1}$  を計算



### ③ $\mathbf{W}$ の大きさに制約

✓ 正則化係数  $\lambda$  を導入

$$p(\mathbf{W} | \lambda) = \left( \frac{\lambda}{2\pi} \right)^{\frac{k^2 m}{2}} \exp \left\{ -\frac{\lambda}{2} \sum_{i=1}^m \sum_{j=1}^{k^2} w_j^{(i)} \right\}$$

### ③ $\mathbf{W}_1$ と $\beta_1$

✓ 主成分分析 (Principal Component Analysis, PCA) を用いて  $\mathbf{W}$  と  $\beta$  との初期値  $\mathbf{W}_1, \beta_1$

✓ 下の式が最小になるような  $\mathbf{W}_1$  を計算

$$\frac{1}{2} \sum_{i=1}^{k^2} \left\| \Phi(\mathbf{z}^{(i)}) \mathbf{W}_1 - \mathbf{z}^{(i)} \mathbf{U} \right\|^2$$

$\mathbf{U}$  : 最初の固有ベクトルと  
二番目の固有ベクトル

✓  $\beta_1$  は三番目の固有値を逆数にしたもの

### ③ $\mathbf{W}$ と $\beta$ の計算

✓ p.24 で  $\mathbf{W}_1, \beta_1$  を計算

✓ 下の3つを、尤度関数が収束するまで繰り返す

- p.20 の Responsibility (R) の計算
- p.21 の  $\mathbf{W}_a, \beta_a \rightarrow \mathbf{W}_{a+1}$  の計算
- p.22 の  $\mathbf{W}_a, \beta_a \rightarrow \beta_{a+1}$  の計算

## ④ 二次元平面上での確率

- ✓ サンプルごとの、二次元平面上の各グリッド (格子点) に存在する確率は、p.19のResponsibility (R) によって計算できる
- ✓ サンプルごとに、全グリッドの R を足すと 1 になる

## ⑤ 二次元平面上の位置

✓ サンプルごとに、確率分布から二次元平面上の位置を決める方法が主に2通りある

- Mode (最頻値): すべてのグリッドの中で  $R$  が最大の位置
- Mean (平均値):  $R$  の値を重みとした重み付き平均

# GTMのハイパーパラメータのそのの意味合い

## ✓マップサイズ： $k$

- 大きめに設定したとしても、計算時間が多めにかかるだけで、オーバーフィッティングへの影響はほとんどない

## ✓基底関数の数： $q$

- 基底関数を多くすると、柔軟に可視化・見える化できるが、オーバーフィッティングの危険も高くなる

## ✓基底関数の標準偏差： $\sigma$

- 大きいほど滑らかな二次元平面になる
- データセットが多次元空間に
  - まんべんなく広がっているときは、大きい方がよい
  - 局所的にいくつかかたまって存在していれば、小さい方がよい

## ✓重み $W$ の大きさを決めるパラメータ： $\lambda$

- 0 からスタートし、問題があれば、0.0001, 0.001, ...と、少しずつ大きくする

# GTMのハイパーパラメータの最適化の方法

- ✓クロスバリデーションの”誤差”が最小になるパラメータの組み合わせ
- ✓サンプルごとの、最もユークリッド距離の小さい  $k$  個のサンプルとの中点をテストサンプルとしてあつかい、テストサンプルの”誤差”が最小となるパラメータの組み合わせ
  - ”誤差”とは、多次元空間上のサンプル点と、二次元平面に写像したあとに、もう一度多次元空間に戻した点とのRMSE (Root-Mean-Squared Error)

# 逆写像

- ✓GTMにより、あるサンプルを二次元平面上に写像できる
- ✓二次元平面上に写像された点を、元の空間に戻してあげることを逆写像という
- ✓元のサンプル点と逆写像された点との距離を見ることで、サンプル点が二次元平面とどれくらい近いかが分かる
- ✓離れているサンプルは、適切に写像されていない、外れ値である、などの議論ができる



# 逆写像のしかた

- ✓ある  $\mathbf{z}^{(j)}$  に対して、 $\Phi(\mathbf{z}^{(j)})\mathbf{W}$  により多次元平面上に逆写像できる
- ✓Responsibility (R) を考慮した逆写像
  - あるサンプルに対して、p.20 の Responsibility (R) を計算する
  - $j$  番目のグリッド点に対応する R を  $\Phi(\mathbf{z}^{(j)})\mathbf{W}$  の重みとみなして、 $\Phi(\mathbf{z}^{(j)})\mathbf{W}$  を重み付き平均した座標が、対象としたサンプルを逆写像した点である