

# 識別的離散ガウス過程潜在変数モデルによるユーザー選好の可視化

竹原 一彰 統計科学専攻 博士課程 (3 年次編入学) 5 年

## 1. 背景：選好可視化の重要性

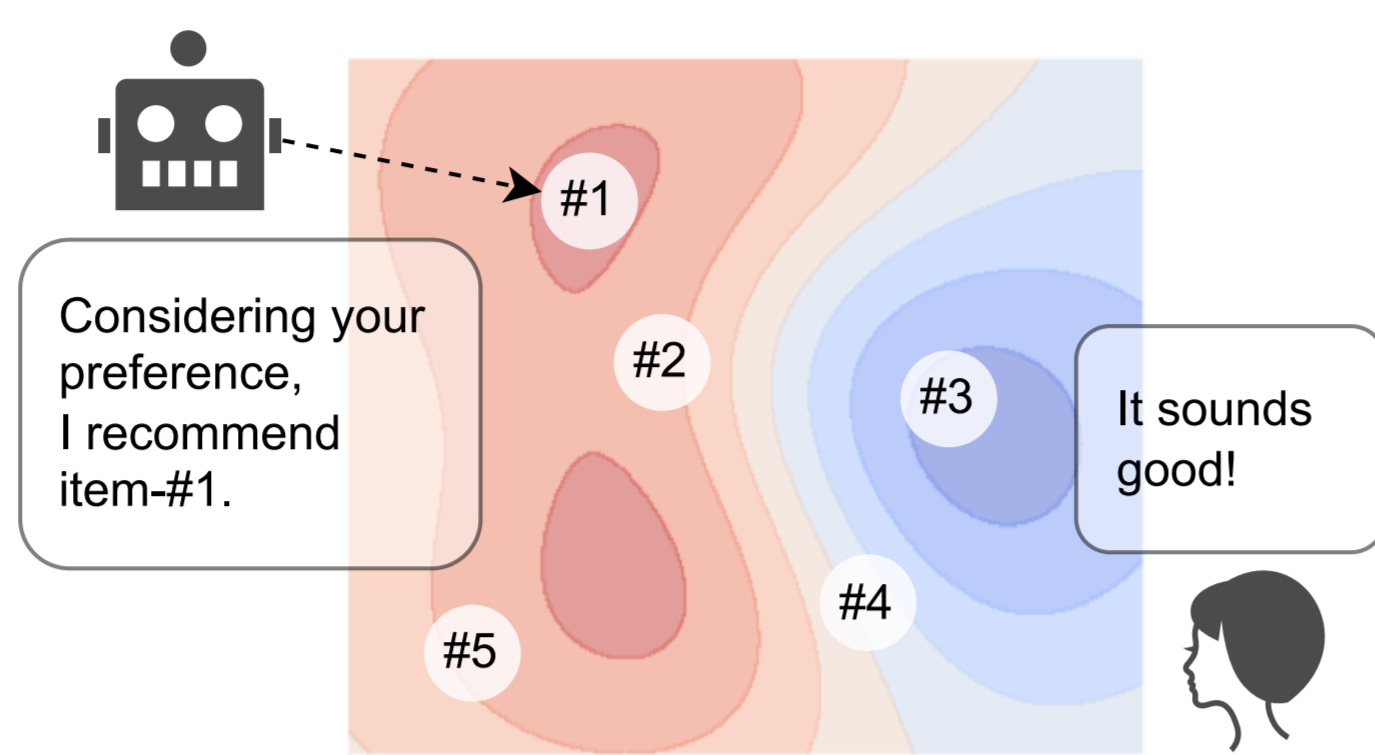
ユーザー選好の可視化は、ユーザーと推薦システム双方にとって重要である。

### システム

推薦の根拠を自然に示すことができる。

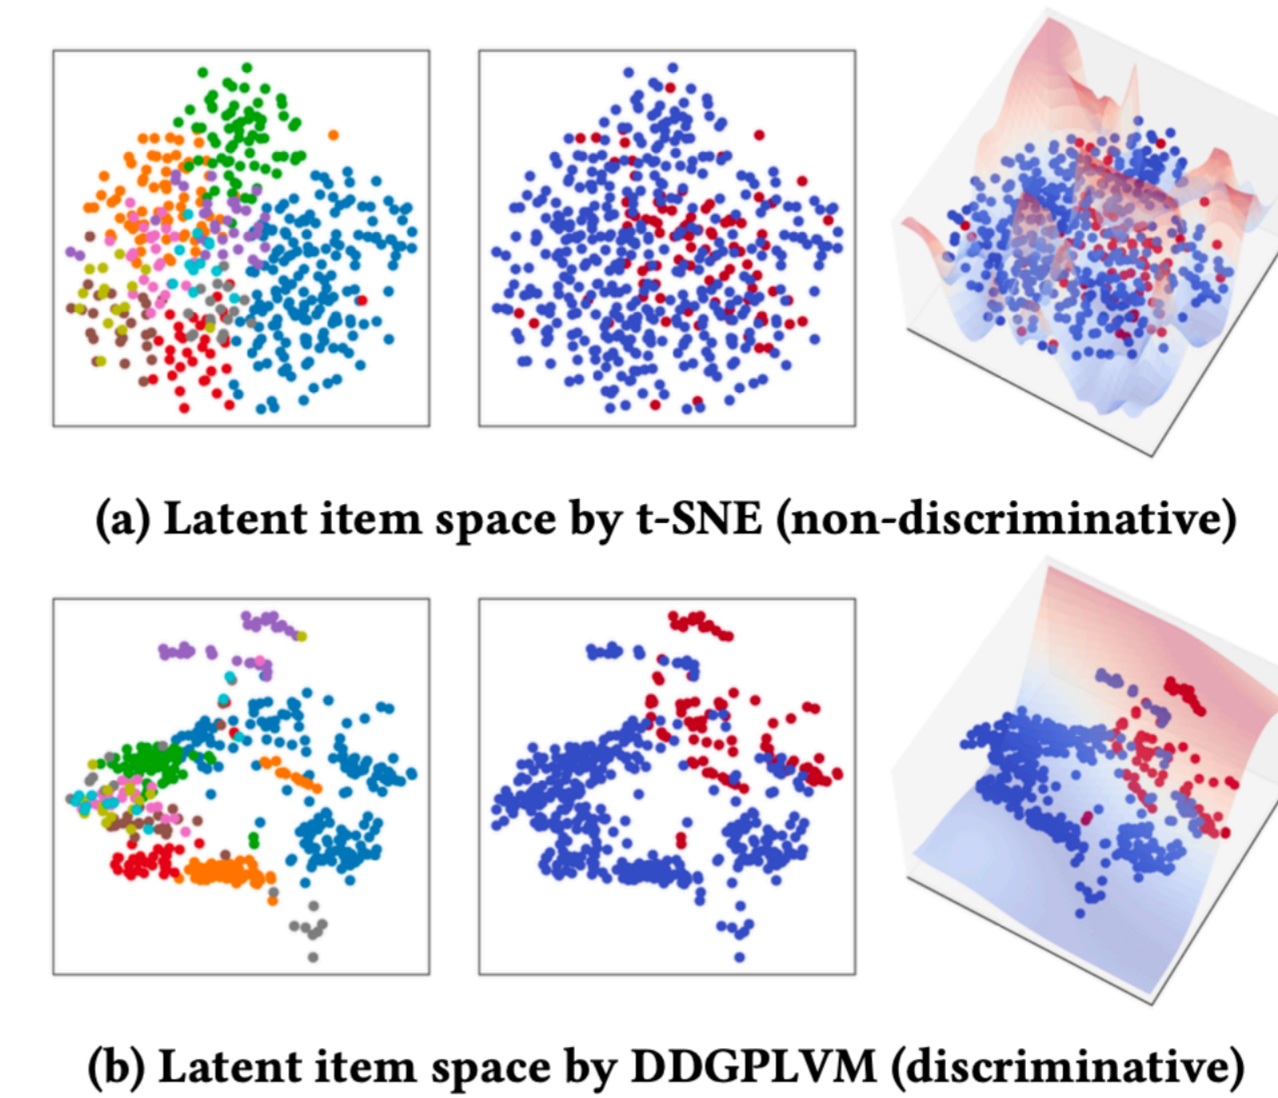
### ユーザー

推薦のよし悪しを判断したり、選好を物差しに探索を進めたりできる。



## 2. 目的：なめらかな関数として選好を可視化

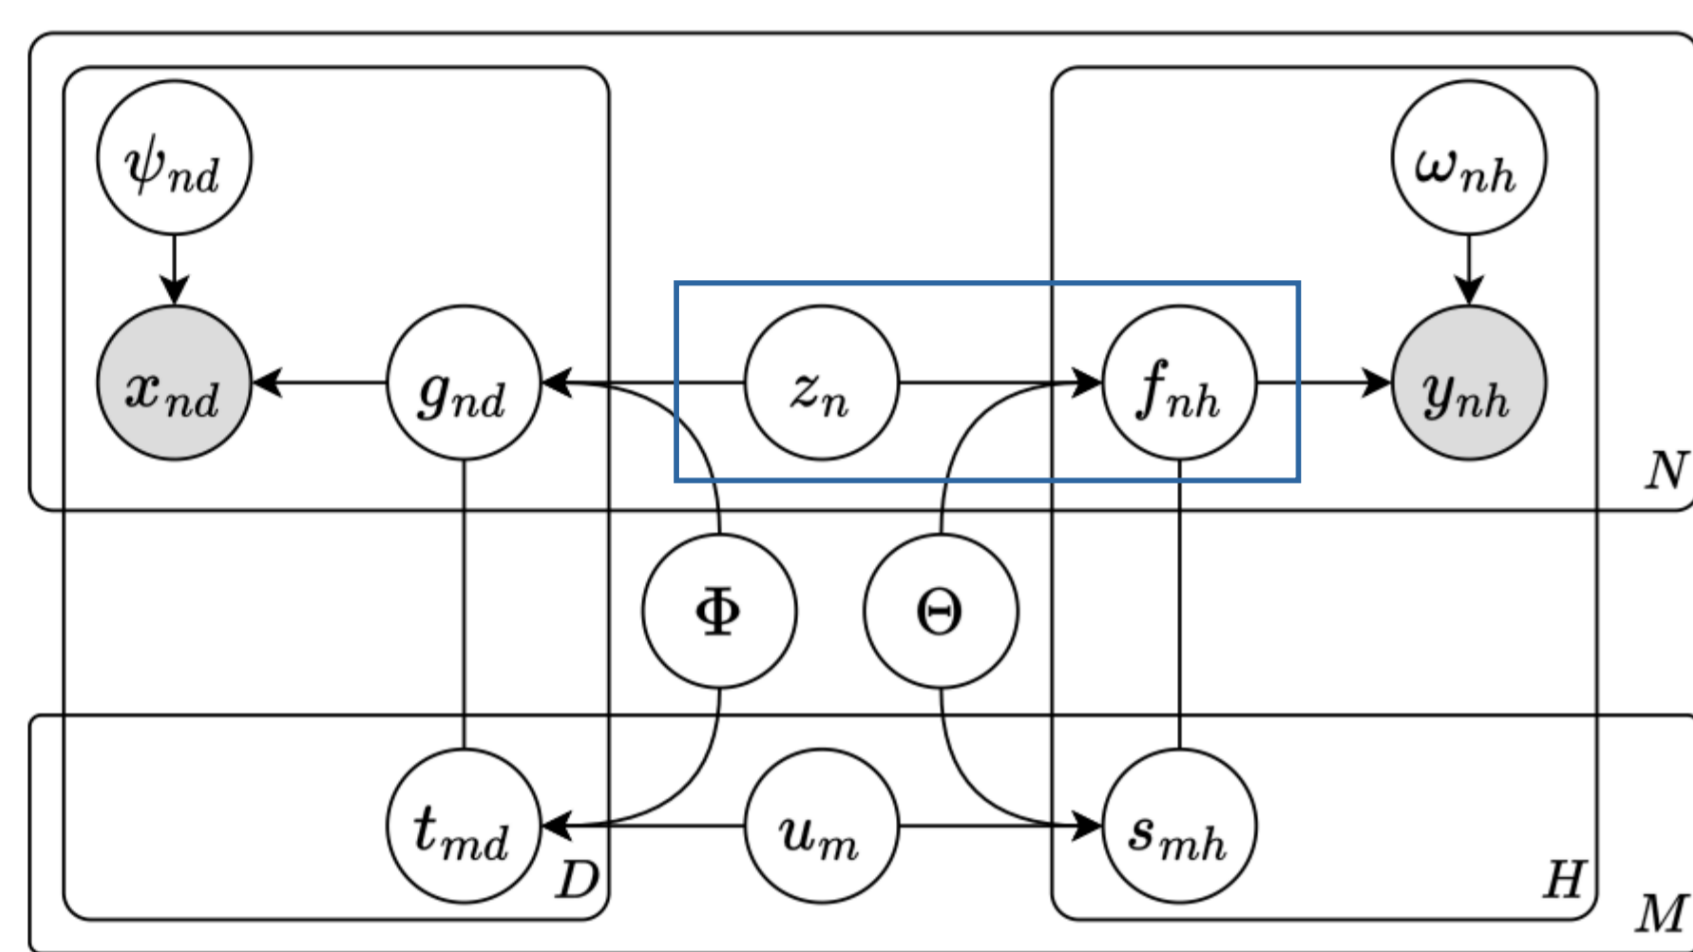
低次元アイテム空間上の、なめらかな関数として、ユーザーの選好を可視化する。



なめらかな選好関数を得るには、次のことが必要。

1. 潜在空間の**識別的な分離**
2. 離散的な評価ラベルから**連続的な選好の推定**

## 3. 手法：識別的離散ガウス過程潜在変数モデル (Discriminative Discrete GPLVM, DDGPLVM)



Notation	Description
$x_n \in X \in \{0, 1\}^{N \times D}$	$D$ dimensional, $N$ items.
$y_h \in Y \in \{0, 1\}^{N \times H}$	$H$ users, $N$ rating labels to $X$ .
$z_n \in Z \in \mathbb{R}^{N \times L}$	$L$ dimensional, $N$ latent items.
$f_h \in F \in \mathbb{R}^{N \times H}$	Latent user preferences of $Y$
$g_d \in G \in \mathbb{R}^{N \times D}$	Latent item features of $X$
$u_m \in U \in \mathbb{R}^{M \times L}$	$L$ dimensional, $M$ inducing inputs
$t_d \in T \in \mathbb{R}^{M \times D}$	Inducing variables for $G$
$s_h \in S \in \mathbb{R}^{M \times H}$	Inducing variables for $F$
$\psi_{nd} \in \Psi, \omega_{nh} \in \Omega$	Pólya-Gamma auxiliary variables
$\Phi, \Theta$	Kernel parameters

### 推論アルゴリズムの 3つの課題

#### 1) 識別的な潜在空間の獲得 $\Rightarrow$ 識別尤度の導入

$$p(Z|F, G, S, T, U, \Theta, \Phi) \propto \underbrace{p(F|S, U, Z, \Theta)}_{\text{識別尤度}} \times \underbrace{p(G|T, U, Z, \Phi)p(Z)}_{\text{GPLVMの事後分布}}$$

#### 2) 計算コスト削減

$\Rightarrow$  **ガウス過程のスパース近似** [Quinonero+ 2005]

$$s_h \sim \mathcal{GP}(0, K_U)$$

$$f_h | S, U, Z \sim \text{SparseGP}(\mu_{f_h}, \Lambda)$$

$$\sim \mathcal{N}(f_h | \mu_{f_h}, \Lambda)$$

$$\mu_{f_h} = K_{ZU} K_U^{-1} s_h, \Lambda = \text{diag}(\lambda_1, \dots, \lambda_N),$$

$$\lambda_n = (K_Z - K_{ZU} K_U^{-1} K_{UZ})_{nn}$$

$K_Z^{-1} \in \mathbb{R}^{N \times N}$  ではなく、 $K_U^{-1} \in \mathbb{R}^{M \times M}$  を用いた計算で近似する。計算量を  $O(N^3)$  から  $O(NM^2 + M^3)$  へと削減。

#### 3) 離散 (Bernoulli) 尤度のガウス共役化

$$p(f_h | y_h) \propto p(y_h | f_h) p(f_h)$$

$$= \prod_{n=1}^N \text{Bern}(y_{nh} | f_{nh}) \times \mathcal{N}(f_h | 0, K_Z)$$

**離散尤度 (ガウス非共役)**

$\Rightarrow$  **Pólya-Gamma 補助変数法** [Polson+ 2013]

$$\text{Bern}(y_{nh} | f_{nh}) = \frac{(e^{f_{nh}})^{y_{nh}}}{(1 + e^{f_{nh}})^1}$$

$$\propto \frac{1}{2} \exp(-\omega_{nh} f_{nh}^2 / 2 + \kappa_{nh} f_{nh})$$


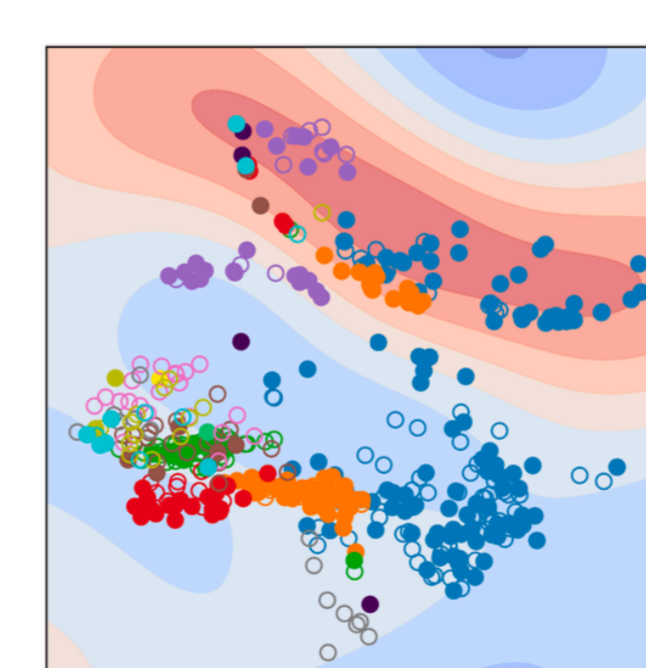

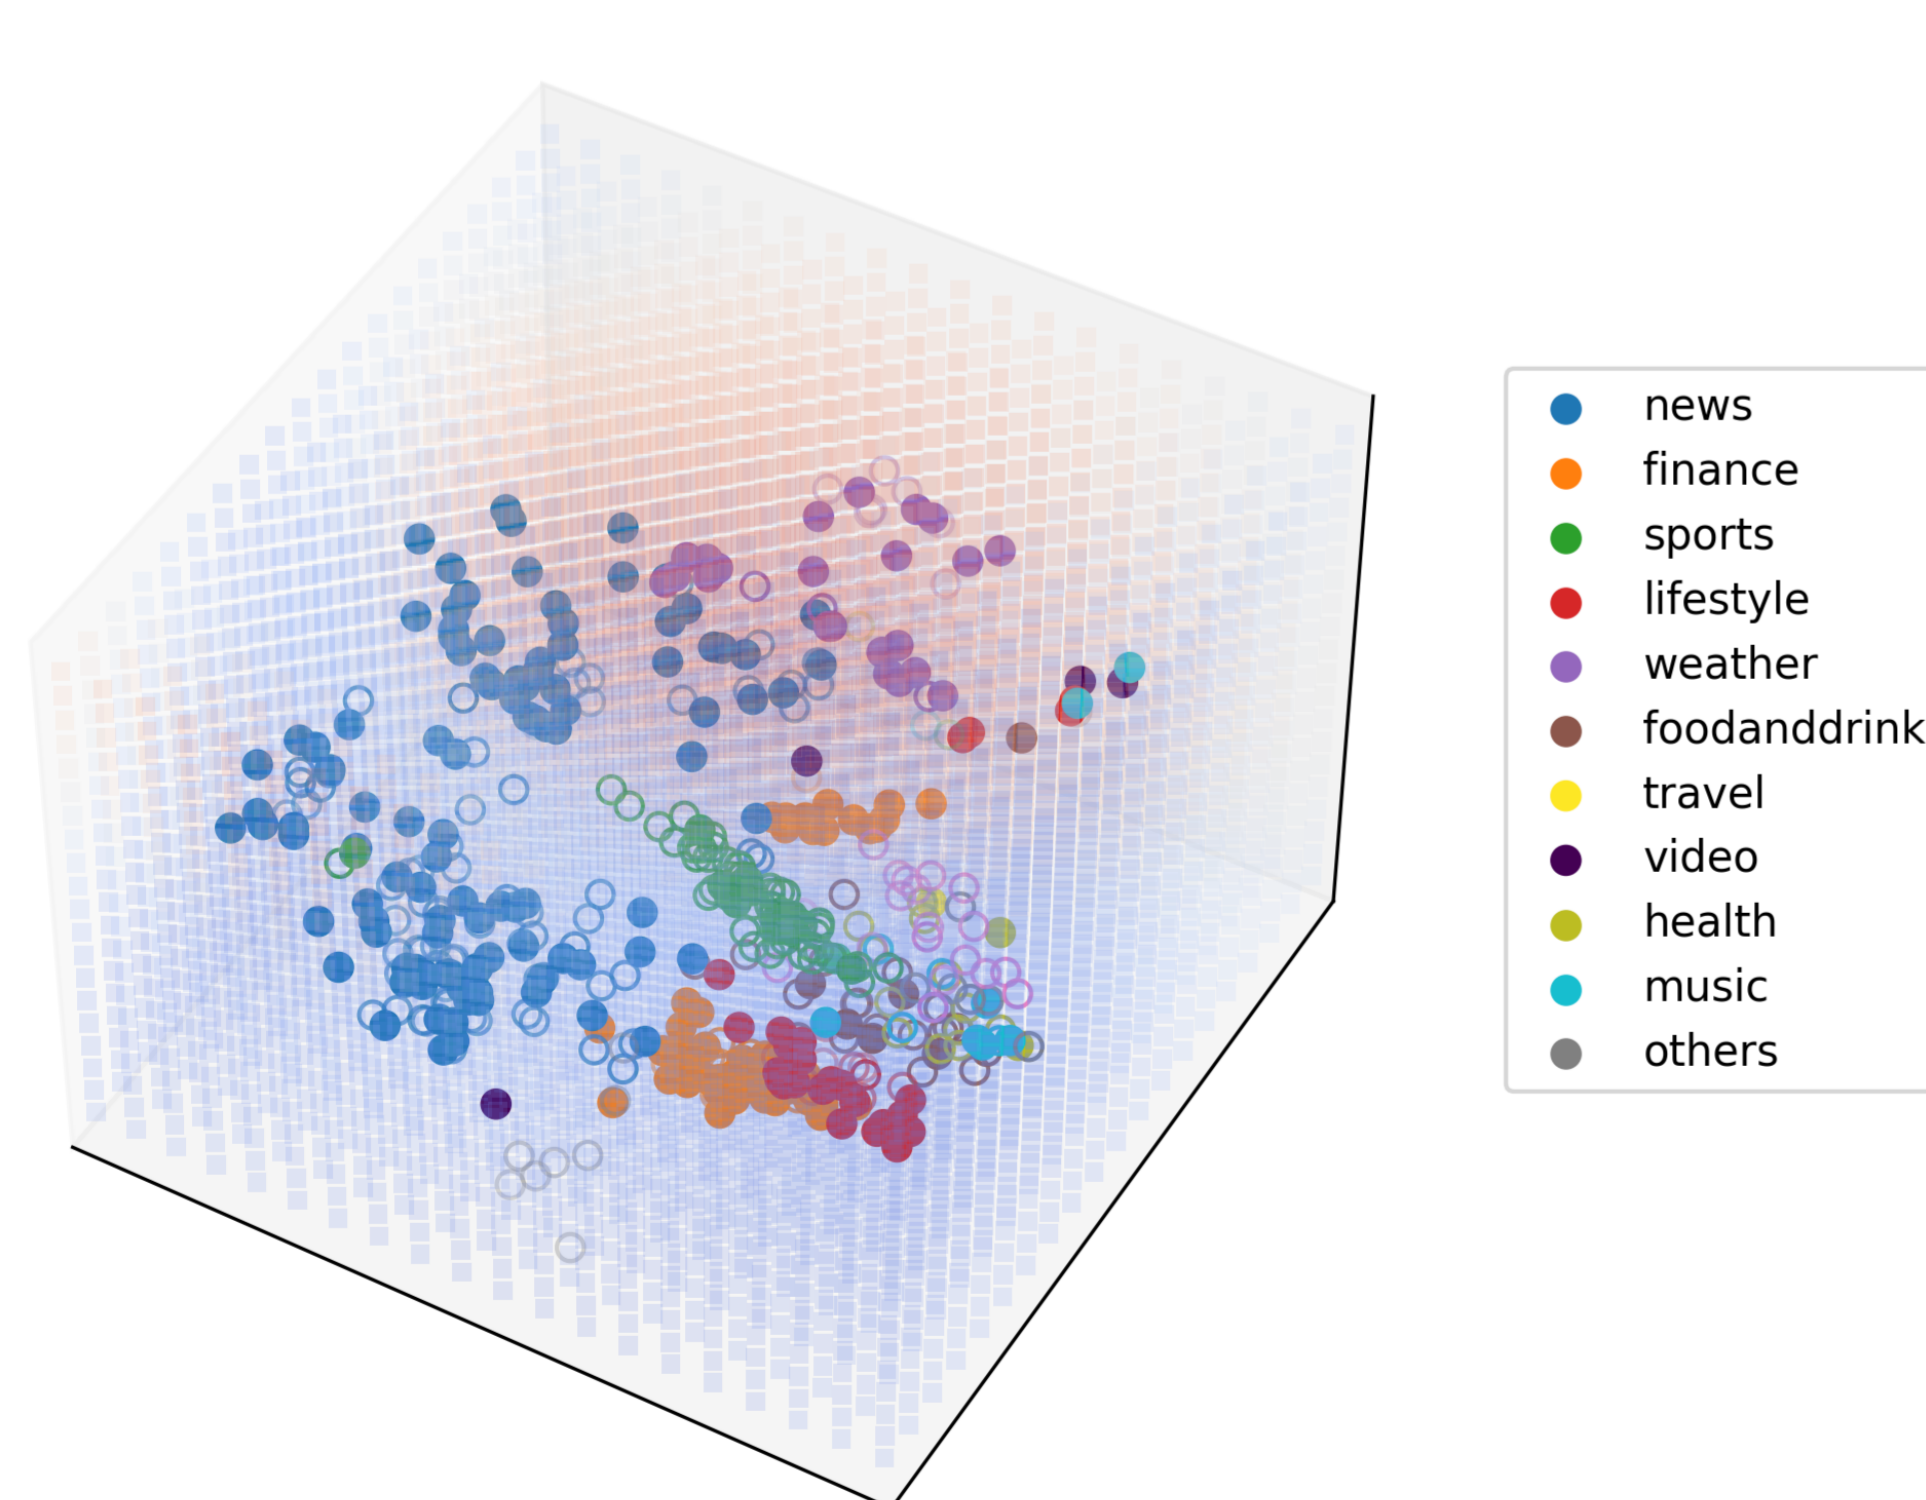
$$(\kappa_{nh} = y_{nh} - 1/2)$$

離散 (Bernoulli) 尤度を  $\exp(-x^2)$  の形にできる。**ガウス共役** となりギブスサンプラーが導出できる。

## 4. 評価：潜在空間と選好の可視化、kNN 分類器を用いた予測精度

識別的な潜在空間となめらかな選好関数を定性的に確認。

アイテム情報  $x_d \in X$  と、評価ラベル  $y_h \in Y$  が、潜在空間に反映されていることを、定量的に確認。



(凡例)

- ・赤：CLICK、青：NOT CLICK
- ・塗りつぶし：評価済、白抜き：未評価
- ・等高線：選好の高さ (青 < 赤)

Dataset	Target	DDGPLVM	DGPLVM *1	GPLVM	LDA	PCA	t-SNE	VAE
MIND-H1	$y_h$	1.000 ± 0.000	(0.786 ± 0.010)	0.892 ± 0.005	0.956 ± 0.008	0.931 ± 0.002	0.946 ± 0.003	0.895 ± 0.004
	$x_d$	0.896 ± 0.003	(0.948 ± 0.008)	0.902 ± 0.002	0.902 ± 0.004	0.899 ± 0.002	0.918 ± 0.003	0.897 ± 0.003
MIND-H5	$y_h$	0.997 ± 0.001	(0.858 ± 0.015)	0.892 ± 0.005	0.979 ± 0.002	0.894 ± 0.004	0.942 ± 0.004	0.958 ± 0.003
	$x_d$	0.898 ± 0.004	(0.957 ± 0.012)	0.902 ± 0.002	0.898 ± 0.003	0.911 ± 0.002	0.925 ± 0.003	0.901 ± 0.004

ニュース閲覧のデータセット MIND (<https://msnews.github.io/>) を利用。

### 参考文献

[Lawrence 2003] Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data.

[Quinonero+ 2005] A unifying view of sparse approximate Gaussian process regression.

[Polson+ 2013] Bayesian Inference for Logistic Models Using Polya-Gamma.

[竹原,持橋 2023] ユーザー選好可視化のための識別的な離散ベイズガウス過程潜在変数モデル, JSAI.