

カーネル法によるノンパラメトリックなベイズ推論とその応用

福水 健次

数理・推論研究系 教授 / 統計的機械学習研究センター長

■ カーネル法

正定値カーネルを用いた、データの非線形性、高次モーメントを取り込むための新しい方法論。効率的な計算を重視。

- **定義: 正定値カーネル** Ω : 集合. $k: \Omega \times \Omega \rightarrow \mathbf{R}$ が正定値であるとは、 k が対称で任意の $n \in \mathbf{N}$, $x_1, \dots, x_n \in \Omega$ に対し、

$$\text{グラム行列} \begin{pmatrix} k(x_1, x_1) & \dots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \dots & k(x_n, x_n) \end{pmatrix} \text{ が半正定値.}$$


例: ガウスクーネル $\exp(-\|x - y\|^2 / (2\sigma^2))$

- **再生核ヒルベルト空間 (RKHS)**

- 正定値カーネルに対しヒルベルト空間が一意に定まる。
- Ω 上の関数からなる関数空間。一般に無限次元。
- 特殊な内積を持つ。

$$\langle k(\cdot, x), f \rangle_{\mathcal{H}} = f(x) \quad \forall f \in \mathcal{H}, x \in \Omega. \quad (\text{再生性})$$

- 正定値カーネルとRKHSを用いたデータ解析



- 特徴写像と特徴ベクトル

$$\Phi: \Omega \rightarrow H, \quad x \mapsto \Phi(x) := k(\cdot, x).$$

- カーネルトリック: 容易な内積計算

$$\langle \Phi(x), \Phi(y) \rangle = \langle k(\cdot, x), k(\cdot, y) \rangle = k(x, y).$$

- 特徴空間上で線形の解析手法を適用 (注: 多くの手法は内積計算が本質的)
 → カーネルPCA, サポートベクターマシン etc
- 非線形カーネル → 非線形/高次情報の抽出

■ カーネル平均による分布の表現

- **カーネル平均:** 特徴ベクトル $\Phi(X)$ の期待値
 $m_P = E_{X \sim P}[\Phi(X)] = \int k(\cdot, x) dP(x)$
 P の積分変換

- **特長的なカーネル**
 m_P により P を一意に決める (例: ガウスクーネル)


- **カーネル平均によるノンパラメトリック推論**

原理: 特長的なカーネルを用いると、
分布に関する推論 → カーネル平均に関する推論

例: 2標本問題 $m_X = m_Y$? (Gretton et al. NIPS'06),
独立性検定 $m_{(X,Y)} = m_X \otimes m_Y$? (Gretton et al. NIPS'07)

- **重み付サンプルによる推論**
サンプルによる表現

$$\hat{m}_X = \sum_{i=1}^N w_i \Phi(X_i)$$



重み付サンプル (X_i, w_i) による表現とみなせる
重みは負も現れる。

■ カーネル法による粒子フィルタ

観測モデルの密度関数(尤度)が書けない場合の粒子フィルタ
サンプリングは可能とする。

例) α -stable Stochastic Volatility model

$$x_t = \phi x_{t-1} + v_t, \quad v_t \sim N(0, \sigma_v^2) \quad x_t: \text{log volatility}$$

$$y_t = e^{x_t/2} w_t, \quad w_t \sim S(\alpha, 0, \sigma_w) \quad y_t: \text{return}$$

y_1, \dots, y_t : 観測系列

- 事後確率 $p(X_t | y_1, \dots, y_t)$ のパーティクル表現:

$$\frac{1}{N} \sum_{i=1}^N \Phi(Z_i^t)$$

- **Prediction step:**

$$\text{サンプリング } X_i^{t+1} \sim p(x_{t+1} | x_t = Z_i^t)$$

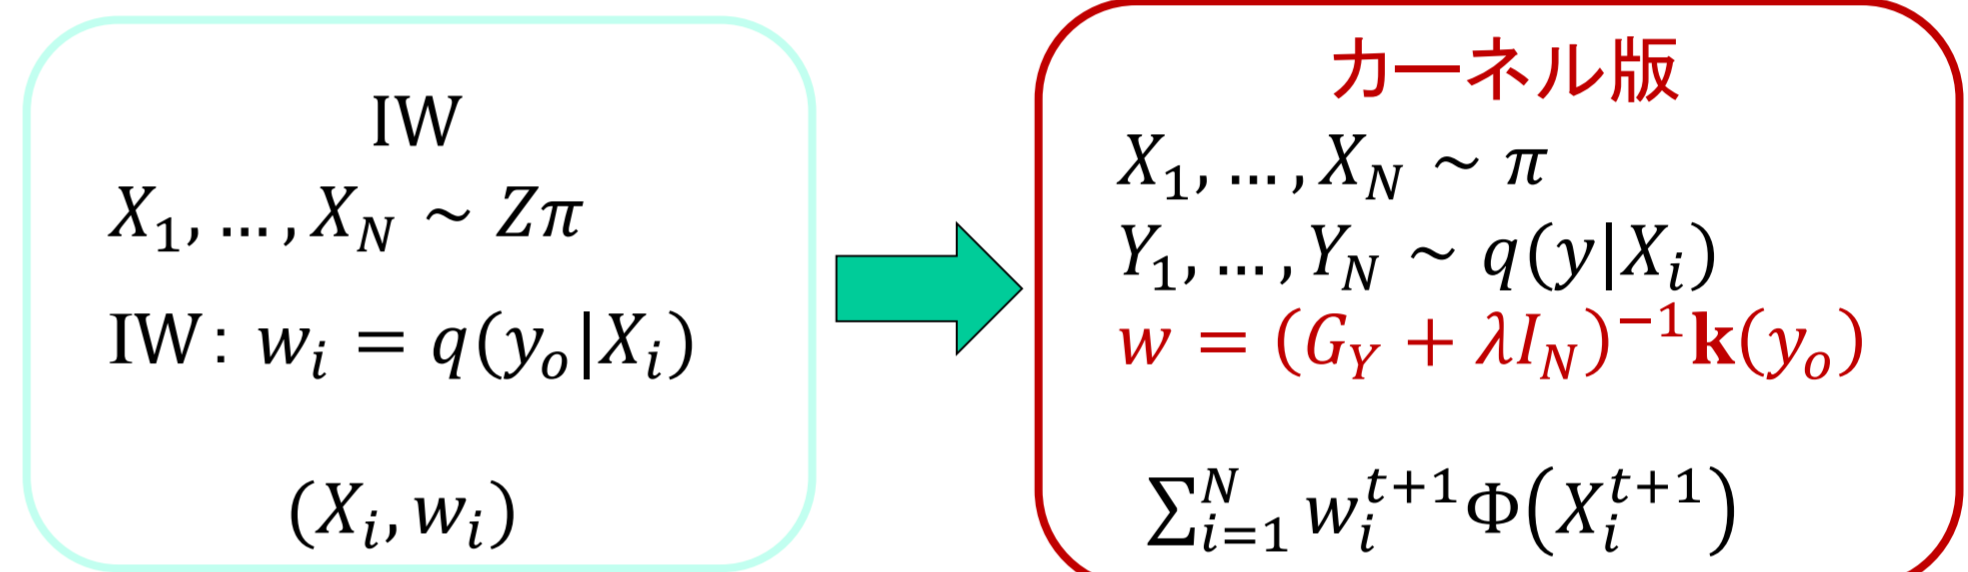
$$Y_i^{t+1} \sim p(y_{t+1} | x_{t+1} = X_i^{t+1}) \quad (i = 1, \dots, N)$$

- **Correction step:**

Importance weightingのカーネル化(線形演算)

$$\pi: \text{prior}, q(y|x): \text{likelihood} \Rightarrow \text{posterior} \propto q(y_o|x)\pi(x)$$

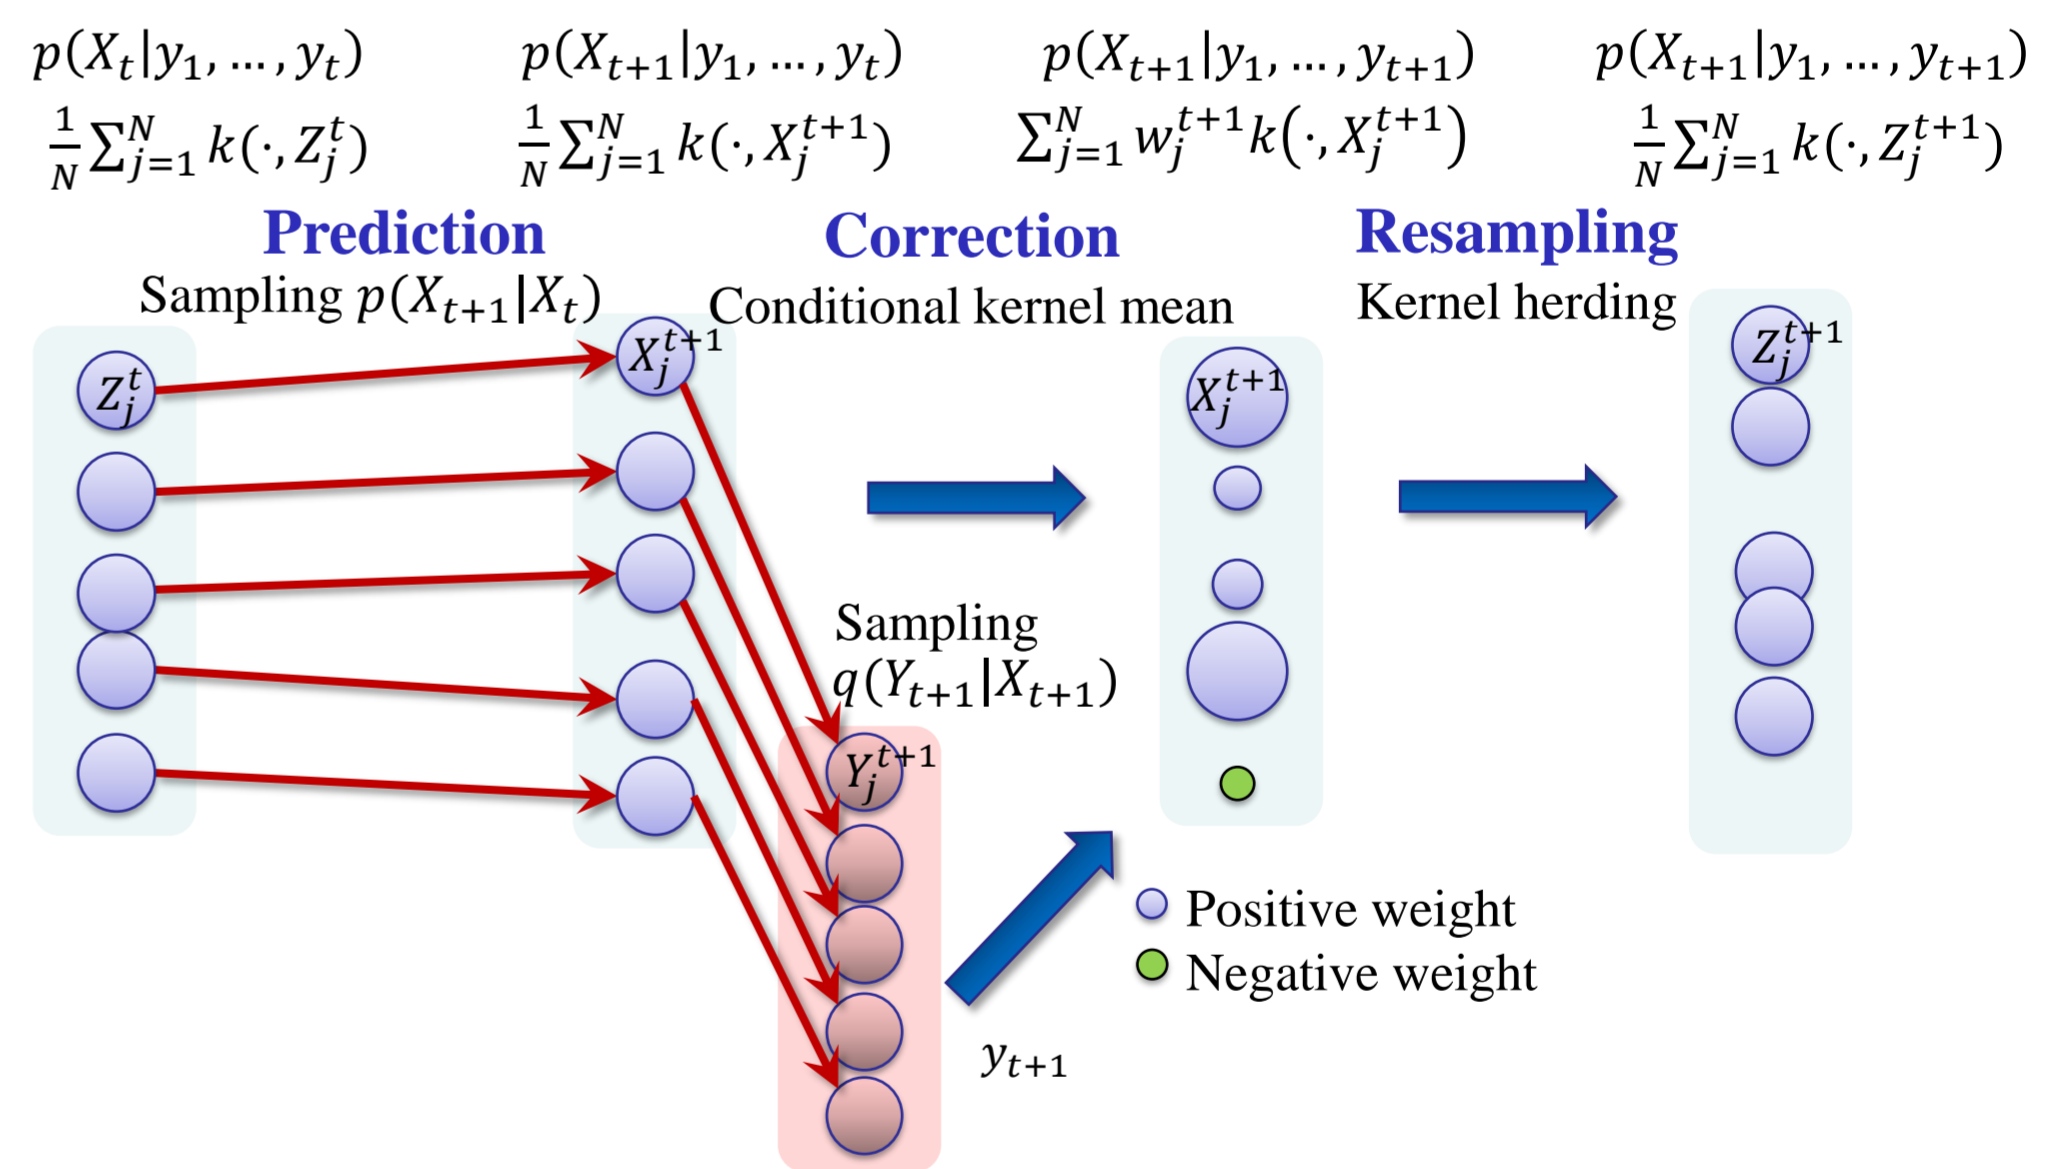
y_o : 観測値



- **Resampling step:** Kernel herding による「リサンプリング」

$$\sum_{i=1}^N w_i^{t+1} \Phi(X_i^{t+1}) \Rightarrow \frac{1}{N} \sum_{i=1}^N \Phi(Z_i^{t+1}) \text{ で近似}$$

一様重み



- 多変量Stochastic Volatility model への応用

$\alpha = 1.5, 2.0$ (Gauss)
ABC filter (Calvet&Czeller 2014),
標準的 Seq. MC (SIR) との比較

