

# ベイズ型再構成法

- 画像の有する滑らかさなどの**事前情報 (prior)** を統計的方法に組み込む
- 事前情報はベイズの定理に基づく

$$P(\lambda|y) = \frac{P(y|\lambda)P(\lambda)}{P(y)} \propto P(y|\lambda)P(\lambda) = L(\lambda)P(\lambda)$$

事後分布 尤度


$y$  : 投影データ  
 $\lambda$  : 画像 (放射能分布)

対数をとる

$$\hat{\lambda} = \operatorname{argmax}_{\lambda} [\ln L(\lambda) + \ln P(\lambda)]$$

MAP推定の目的関数

事前分布 $P(\lambda)$ を上式に与え、そのときの事後分布 $P(\lambda|y)$ の最大値 $\hat{\lambda}$ を求める  
 → Maximum a posteriori (MAP)



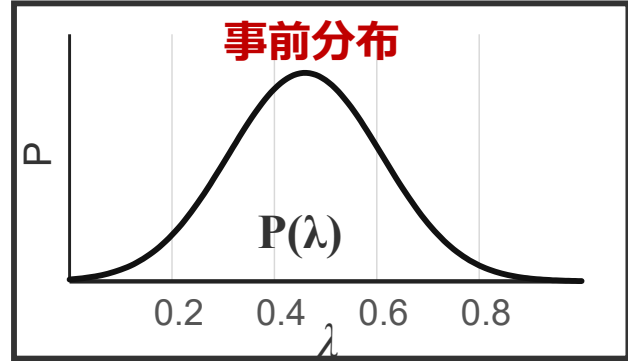
# 事前情報 (Prior) とは

ベイズ的に考える：事前情報を投影データで更新する

$$P(\lambda|y) \propto P(y|\lambda)P(\lambda) = L(\lambda)P(\lambda)$$

事後分布
尤度
事前分布
尤度
事前分布

投影データを見る前の仮定  
= 事前情報



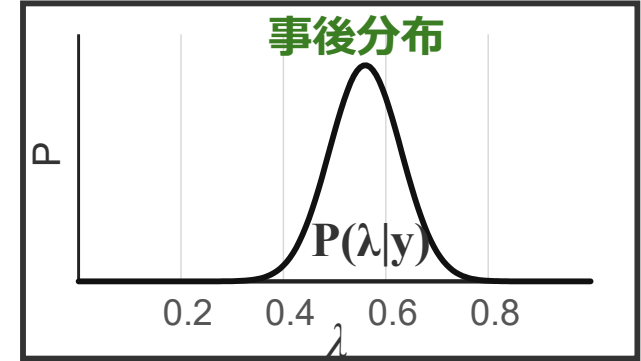
画像 $\lambda$ に対する仮定  
例：滑らかさ・エッジ保持

投影データ  $y$  を反映して  
事後分布を求める

$L(\lambda) = P(y|\lambda)$   
 $y$  : 投影データ  
 画像  $\lambda$  から  
 $y$  が観測される  
 尤もらしさ

投影データへの適合度

投影データで更新された分布



事後分布が最大となる  
画像  $\hat{\lambda}$  を推定

MAP推定：事前分布  $P(\lambda)$  と尤度  $L(\lambda)$  から、事後分布  $P(\lambda|y)$  が最大となる画像  $\hat{\lambda}$  を求める

# 正則化項 $R$ の代表例

## ■ Gibbs事前分布

$$P(\lambda) = \frac{1}{Z(\beta)} \exp\{-\beta R(\lambda)\}$$

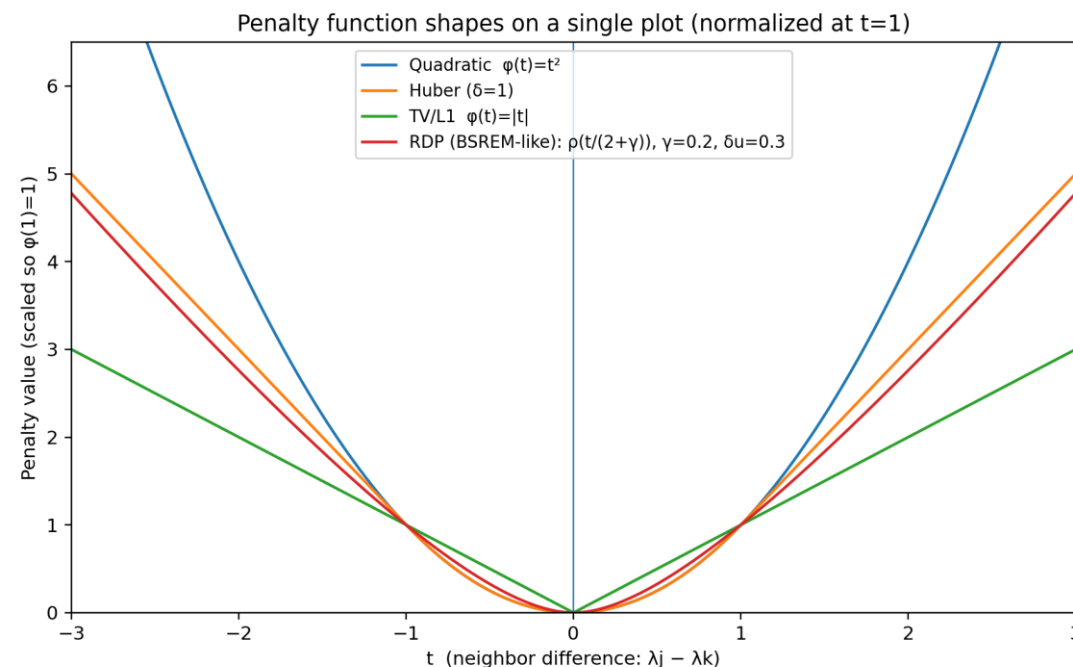
$$R(\lambda) = \sum_j \sum_{k \in \mathcal{N}_{(j)}} w_{jk} \phi(\lambda_j - \lambda_k)$$

事前分布：滑らかで、構造を保持する画像を高く評価する  
正則化：滑らかでない画像に罰則を与える

$\mathcal{N}(j)$  : 近傍ボクセル  
 $w_{jk}$  : 距離・方向に応じた重み  
 $\phi(\cdot)$  : ペナルティ形状

## ■ 代表的なペナルティ関数

- ✓ Quadratic (二次関数) : 強い平滑化
- ✓ Huber : エッジ保存
- ✓ Total variation : エッジ保存
- ✓ Relative difference : ノイズ抑制とエッジ保存

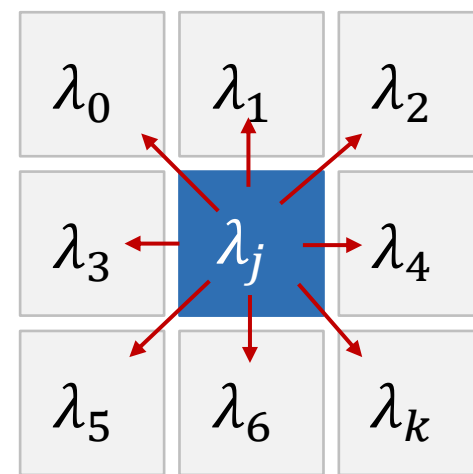


# RDPでは集積によって正則化強度が異なる

## ■ RDP

$$R(\lambda) = \sum_j \sum_{k \in N_j} w_{jk} \sqrt{\beta_j \beta_k} \frac{(\lambda_j - \lambda_k)^2}{\lambda_j + \lambda_k + \gamma |\lambda_j - \lambda_k|}$$

$\beta_j, \beta_k$  : 画素ごとの正則化重み



- ✓ 低集積は 同じ  $\Delta$  でも正則化が大きい  
→ 平滑化されやすい
- ✓  $\Delta$  が大きくなると  $|\Delta|/\gamma$  (一次関数) に近づく  
→ エッジ保存されやすい

\* $S = \lambda_j + \lambda_k$ ,  $\Delta = \lambda_j - \lambda_k$  とする

