

Das Potts-Modell zum Entrauschen digitaler Mammographien



Projektvortrag, 1.10.2002

Katrin Wicker

Überblick

- Einleitung, Modellvorstellung
- Das 1d Potts Modell
- Das 2d Potts Modell
- Berechnungsregeln
- Demonstration

Anwendungsbezogenes Fernziel: Detektion von Mikrokalken in Mammographien.




Ein Ausschnitt aus einer Mammographie, rechts Mikrokalke von einem Radiologen eingefärbt.

- Restauration mit Potts Modell soll allerersten Schritt für weitere Analyse der Daten mit anderen Methoden sein.
- Ziel: möglichst unspezifische Vereinfachung des Signals
- Inhalt des Projektes: Implementierung eines 2d Quasi-Potts-Minimierers, Anwendung auf Mammographien.

Modellvorstellung

Gegeben: Beobachtung $y = \{y_1, \dots, y_n\}$, $y_i \in \mathbb{R}$, $n, d \in \mathbb{N}$




Gesucht: „Rekonstruktion“ $x = \{x_1, \dots, x_n\}$

Suche möglichst gute Approximation von y durch ein stückweise konstantes Signal x . (deterministisch)

Potts Modell:

$$H_y(x) := \gamma \sum_{s \sim t} |x_s \neq x_t| + \sum_{i=1}^n (x_i - y_i)^2$$

Partitionen



- $P = (I_1, \dots, I_n)$: Partition von $\{1, \dots, N\}$, $n \leq N$
- $\mu = (\mu_1, \dots, \mu_n)$, $\mu_i \in \mathbb{R}$: Werte auf Intervallen
- P^l : Partition von $\{1, \dots, l\}$, $l \leq N$
- $Q_l^k = \{l, \dots, k\}$: Partition mit einem Intervall

Modell auf Partitionen:

$$h_y(P) := \gamma[|P| - 1] + \sum_{i=1}^n \sum_{j \in I_i} (\mu_i - y_j)^2$$

Sei $I \subset \{1, \dots, N\}$:

$$\hat{\mu}(I) := \frac{1}{|I|} \sum_{i \in I} y_i,$$

$$\hat{\sigma}(I) := \sum_{i \in I} (\hat{\mu}(I) - y_i)^2$$

Satz 1 Sei eine Partition P von $\{1, \dots, N\}$ fest gegeben. Der Minimierer der Funktion $h_y(P)$ (in μ) unter allen auf den Intervallen I_1, \dots, I_n konstanten Vektoren ist

$$\hat{\mu}(P) = (\hat{\mu}(I_1), \dots, \hat{\mu}(I_n))$$

Lemma 1 Es existiert ein Minimierer \hat{P} für $h_y(P)$ (in μ und P).

Der Minimierer von h_y

Lemma 2 Seien p, q Teil-Partitionen von P mit $P = (p, q)$, dann

$$h_y(p, q) = h_y(p) + h_y(q) + \gamma$$

und $h_y(I) = \hat{\sigma}(I)$ für ein Intervall I .


Satz 2 Seien $1 \leq l < k \leq N$ und $P_l^k = (\hat{P}^l, Q_{l+1}^k)$.

Sei \hat{l} Minimierer von $h_y(P_l^k)$ (d.h. $h_y(P_{\hat{l}}^k) = \min_{l \in \{1, \dots, k-1\}} h_y(P_l^k)$).

Dann ist

$$h_y(P_{\hat{l}}^k) = h_y(\hat{P}^k)$$


Satz 3 Ein Minimierer von h_y ist Minimierer von H_y .



Der Algorithmus

- VAR \hat{l} : ARRAY $N + 1$ OF INT; h : ARRAY $N + 1$ OF REAL;
- $h(0) = h(1) := 0, l(0) = l(1) := 0, k := 2$
- WHILE($k \leq N$) DO
 $\hat{l}(k) := \arg \min_{l \in \{0, \dots, k-1\}} (h(l) + \gamma + \sigma_{l+1}^k)$
 $h(k) := \min_{l \in \{0, \dots, k-1\}} (h(l) + \gamma + \sigma_{l+1}^k)$
 $k := k + 1$
 END;
- $k := N, \hat{P}^k = P_{\hat{l}(k)}^k$ (rekursiv)

2d Partitionen



- $P = (P_1, \dots, P_n)$: Partition (vertikal) mit
 $P_i = (P_{ij})_{j=1, \dots, m_i} = [(I_i \times I_{i1}), \dots, (I_i \times I_{im_i})]$ (horizontal)
 $|P| := \sum_i m_i$ Anzahl der verallgemeinerten Intervalle
- $\mu = (\mu(J))_{J \in P}$: (konstante) Werte in der Partition

Das 2d Modell

$$\begin{aligned} h_y(P) &:= \gamma|P| + \sum_{J \in P} \sum_{j \in J} (\mu(J) - y_j)^2 \\ &= \sum_{i=1}^n \underbrace{\left[\gamma|P_i| + \sum_{J \in P_i} \sum_{j \in J} (\mu(J) - y_j)^2 \right]}_{h_y^*(P_i)} \end{aligned}$$

- Wie in Satz 1 minimiert $\hat{\mu}$ bei festgelegter Partition P die Funktion $h_y(P)$ (in μ).
- $h_y^*(P_j)$, $1 \leq j \leq n$ läßt sich analog zu Satz 2 minimieren (horizontal), denn mit $p, q \in P_j$, $(p, q) = P_j$ gilt $h_y^*(p, q) = h_y^*(p) + h_y^*(q)$.

Minimierung in 2d

Bezeichne

P^l : Partition von $(1, \dots, l) \times (1, \dots, N_2)$, $l \leq N_1$ und

\hat{Q}_l^k : Minimierer von $h_y^*(Q_l^k)$, mit $Q_l^k = ((J \times J_1), \dots, (J \times J_m))$,
wobei $J = \{l, \dots, k\}$ und (J_1, \dots, J_m) Partition von $(1, \dots, N_2)$,
($1 \leq l < k \leq N_1$, $1 \leq m \leq N_2$).

Satz 2 läßt sich unverändert anwenden:

Satz 4 Seien $1 \leq l < k \leq N_1$ und $P_l^k = (\hat{P}^l, \hat{Q}_{l+1}^k)$.

Sei \hat{l} Minimierer von $h_y(P_l^k)$ (d.h. $h_y(P_{\hat{l}}^k) = \min_{l \in \{1, \dots, k-1\}} h_y(P_l^k)$).

Dann ist

$$h_y(P_{\hat{l}}^k) = h_y(\hat{P}^k)$$

Mittelwert- und Varianzbestimmung

Um die Partitionen in $O((N_1 N_2)^2)$ berechnen zu können, müssen Mittelwert und Varianz der Daten auf Rechtecken in fester Anzahl Schritten bestimmt werden.


Seien dazu $S = \{1, \dots, N_1\} \times \{1, \dots, N_2\}$ und

$$Y = (y_{st})_{(s,t) \in S} = \begin{pmatrix} y_{11} & y_{12} & \cdots & y_{1N_2} \\ \vdots & \vdots & \ddots & \vdots \\ y_{N_1 1} & y_{N_1 2} & \cdots & y_{N_1 N_2} \end{pmatrix},$$
$$B = (b_{st})_{(s,t) \in S} = \sum_{i=1}^s \sum_{j=1}^t y_{ij}.$$

benötigt:

- $\hat{\mu}(I) = \frac{1}{|I|} \sum_{i \in I} y_i$
- $\hat{\sigma}(I) = \sum_{i \in I} (\hat{\mu}(I) - y_i)^2 = \sum y_i^2 - |I|(\hat{\mu}(I))^2$

für Rechtecke $I \subset S$.



$$\begin{aligned}
 \sum_{s \in I_l^k} y_s &= \sum_{\substack{l_1 < i \leq k_1 \\ l_2 < j \leq k_2}} y_{ij} = \sum_{\substack{0 < i \leq k_1 \\ 0 < j \leq k_2}} y_{ij} - \sum_{\substack{0 < i \leq k_1 \\ 0 < j \leq l_2}} y_{ij} - \sum_{\substack{0 < i \leq l_1 \\ 0 < j \leq k_2}} y_{ij} + \sum_{\substack{0 < i \leq l_1 \\ 0 < j \leq l_2}} y_{ij} \\
 &= b_{k_1 k_2} - b_{k_1 l_2} - b_{l_1 k_2} + b_{l_1 l_2}
 \end{aligned}$$

Algorithmus für den 2d Fall

- VAR \hat{l} : ARRAY $N_1 + 1$ OF INT; h : ARRAY $N_1 + 1$ OF REAL;
- $h(0) = h(1) := 0, l(0) = l(1) := 0, k := 2$
- WHILE($k \leq N$) DO
 $\hat{l}(k) := \arg \min_{l \in \{0, \dots, k-1\}} (h(l) + \text{getmin}(l, k))$
 $h(k) := \min_{l \in \{0, \dots, k-1\}} (h(l) + \text{getmin}(l, k))$
 $k := k + 1$
 END;
- $k := N_1, \hat{P}^k = P_{\hat{l}(k)}^k$ (rekursiv)

- `getmin(from,to)`

- ★ `VAR \hat{l} : ARRAY $N_2 + 1$ OF INT; h : ARRAY $N_2 + 1$ OF REAL;`

- ★ `$h(0) = h(1) := 0, l(0) = l(1) := 0$ $k := 2$`

- ★ `WHILE($k \leq N$) DO`

- `$\hat{l}(k) := \arg \min_{l \in \{0, \dots, k-1\}} (h(l) + \hat{\sigma}(\{from, \dots, to\} \times \{l, \dots, j\}) + \gamma)$`


- `$h(k) := \min_{l \in \{0, \dots, k-1\}} (h(l) + \hat{\sigma}(\{from, \dots, to\} \times \{l, \dots, j\}) + \gamma)$`

- `$k := k + 1$`

- `END;`

- `END;`

Demonstration



Original, horizontale und vertikale Rekonstruktion sowie Summe, $\gamma = 0.5$

Beweis zu Satz 2

$$\begin{aligned}h_y(\hat{P}^N) &= \min_{\tilde{P} \in J(\{1, \dots, N\})} h_y(\tilde{P}) \\&= \min_{k \in \{1, \dots, N\}} \min_{\tilde{P} \in J(\{1, \dots, k\})} \{h_y(\tilde{P}, Q_k^N)\} \\&= \min_{k \in \{1, \dots, N\}} \min_{\tilde{P} \in J(\{1, \dots, k\})} (h_y(\tilde{P}) + \gamma + \sigma_k^N) \\&= \min_{k \in \{1, \dots, N\}} \left[\left(\min_{\tilde{P} \in J(\{1, \dots, k\})} h_y(\tilde{P}) \right) + \gamma + \sigma_k^N \right] \\&= \min_{k \in \{1, \dots, N\}} (h_y(\hat{P}^k) + \gamma + \sigma_k^N) \\&= h_y(\hat{P}_{\hat{k}}^N)\end{aligned}$$

Der Schluss des Beweises erfolgt per Induktion.