

Rate Distortion Theory and Information Bottleneck Method

Julien Wolf

17. September 2008

Inhalt

Einführung

Rate Distortion

Definitionen

Eigenschaften

Blahut-Arimoto-Algorithmus

Anwendungen

Information Bottleneck Method

Motivation

Eigenschaften

Iterative Berechnung

Anwendungen

Problemstellung

- ▶ Information ist teuer! Daher: »Was ist relevante Information«?
- ▶ Idee: zulässige Veränderung der Information quantifizieren
- ▶ innerhalb dieser Grenze (verlustbehaftet) komprimieren
- ▶ Übertragung der Information in ein vereinfachtes Alphabet
 \rightsquigarrow “lossy source compression” \rightsquigarrow *rate distortion theory*

Definitionen

- ▶ X (endlicher) Signalraum
- ▶ \tilde{X} "codebook" / komprimiertes Signal
- ▶ stochastische Abbildung $X \rightarrow \tilde{X}$ durch $p(\tilde{x}|x)$
 \rightsquigarrow Partitionierung von X durch $p(\tilde{x}|x)$, mit

$$p(\tilde{x}) = \sum_x p(x)p(\tilde{x}|x) \quad (1)$$

- ▶ Maß für die Kompressionsrate: $I(X; \tilde{X})$
- ▶ distortion function $d: X \times \tilde{X} \rightarrow \mathbb{R}_0^+$
- ▶ Verzerrung bei der Partitionierung von X :

$$\langle d(x, \tilde{x}) \rangle_{p(x, \tilde{x})} = \sum_{x \in X} \sum_{\tilde{x} \in \tilde{X}} p(x, \tilde{x}) d(x, \tilde{x}) \quad (2)$$

Rate distortion function

Definition (rate distortion function)

Es gibt für jede gegebene Verzerrung D eine Untergrenze für die Kompressionsrate:

$$R(D) \equiv \min_{\{p(\tilde{x}|x) : \langle d(x, \tilde{x}) \rangle \leq D\}} I(X; \tilde{X}) \quad (3)$$

Mit Lagrange-Multiplikator β :

$$\mathcal{F}[p(\tilde{x}|x)] = I(X; \tilde{X}) + \beta \langle d(x, \tilde{x}) \rangle_{p(x, \tilde{x})} \quad (4)$$

Eigenschaften von $R(D)$

Theorem

Lösung des Minimierungsproblems:

$$p(\tilde{x}|x) = \frac{p(\tilde{x})}{Z(x, \beta)} \exp(-\beta d(x, \tilde{x})) \quad , \quad (5)$$

wobei $Z(x, \beta)$ eine Zustandssumme ist. Ausserdem ist $\beta > 0$ und es gilt:

$$\frac{\delta R}{\delta D} = -\beta \quad (6)$$

Beweis

$$\begin{aligned}\mathcal{F}[p(\tilde{x}|x)] &= \sum_x \sum_{\tilde{x}} p(x)p(\tilde{x}|x) \log \frac{p(\tilde{x}|x)}{p(\tilde{x})} & (7) \\ &+ \beta \sum_x \sum_{\tilde{x}} p(x)p(\tilde{x}|x)p(x)d(x, \tilde{x}) \\ &+ \sum_x \lambda(x) \sum_{\tilde{x}} p(\tilde{x}|x)\end{aligned}$$

$$\begin{aligned}\left. \frac{\delta \mathcal{F}}{\delta p(\tilde{x}|x)} \right|_{x, \tilde{x}} &= p(x) \left(\log \frac{p(\tilde{x}|x)}{p(\tilde{x})} + 1 - \frac{1}{p(\tilde{x})} \sum_{x'} p(x')p(\tilde{x}|x') \right) & (8) \\ &+ \beta d(x, \tilde{x}) + \frac{\lambda(x)}{p(x)}\end{aligned}$$

$$= p(x) \left(\log \frac{p(\tilde{x}|x)}{p(\tilde{x})} + \beta d(x, \tilde{x}) + \log Z(x, \beta) \right) \quad (9)$$

Beweis

$$\begin{aligned}\mathcal{F}[p(\tilde{x}|x)] &= \sum_x \sum_{\tilde{x}} p(x)p(\tilde{x}|x) \log \frac{p(\tilde{x}|x)}{p(\tilde{x})} & (7) \\ &+ \beta \sum_x \sum_{\tilde{x}} p(x)p(\tilde{x}|x)p(x)d(x, \tilde{x}) \\ &+ \sum_x \lambda(x) \sum_{\tilde{x}} p(\tilde{x}|x)\end{aligned}$$

$$\begin{aligned}\left. \frac{\delta \mathcal{F}}{\delta p(\tilde{x}|x)} \right|_{x, \tilde{x}} &= p(x) \left(\log \frac{p(\tilde{x}|x)}{p(\tilde{x})} + 1 - \frac{1}{p(\tilde{x})} \sum_{x'} p(x')p(\tilde{x}|x') \right) & (8) \\ &+ \beta d(x, \tilde{x}) + \frac{\lambda(x)}{p(x)}\end{aligned}$$

$$= p(x) \left(\log \frac{p(\tilde{x}|x)}{p(\tilde{x})} + \beta d(x, \tilde{x}) + \log Z(x, \beta) \right) \quad (9)$$

Blahut-Arimoto-Algorithmus

Idee:

Minimierung des Abstandes zwischen zwei konvexen Mengen $A, B \in \mathbb{R}^n$ durch abwechselnde Optimierung

Lemma

Gegeben $p(x, y) = p(x)p(y|x)$, dann ist $D_{KL}(p(x, y) | p(x)p(y))$ minimal für die Marginalverteilung

$$p(y) = \sum_x p(x)p(y|x) \quad (10)$$

Blahut-Arimoto-Algorithmus

Ist \mathcal{F} minimal, so sind die beiden Gleichungen

$$p(\tilde{x}) = \sum_x p(x)p(\tilde{x}|x) \quad (11)$$

$$p(\tilde{x}|x) = \frac{p(\tilde{x})}{Z(x, \beta)} \exp(-\beta d(x, \tilde{x})) \quad (12)$$

erfüllt. \mathcal{F} kann nun über die die konvexen Mengen $\{p(\tilde{x})\}$ und $\{p(\tilde{x}|x)\}$ minimiert werden:

$$\min_{p(\tilde{x})} \min_{p(\tilde{x}|x)} \mathcal{F}[p(\tilde{x}); p(\tilde{x}|x)] \quad (13)$$

Blahut-Arimoto-Algorithmus

Iteration:

$$\begin{cases} p_{t+1}(\tilde{x}) = \sum_x p(x)p_t(\tilde{x}|x) \\ p_t(\tilde{x}|x) = \frac{p_t(\tilde{x})}{Z_t(x,\beta)} \exp(-\beta d(x, \tilde{x})) \end{cases} \quad (14)$$

Konvergiert zu einem eindeutigen Minimum von \mathcal{F} .

Anwendungen

- ▶ »relevant quantization« z.B. für Bilder (JPEG, MPEG)
- ▶ perception-based distortion measures

Motivation

- ▶ *Bisher: distortion function* muß definiert werden.
- ▶ *Idee:* relevant ist, was X über Y aussagt.

$$I(\tilde{X}; Y) \leq I(X; Y) \quad (15)$$

- ▶ *Ziel:* $I(\tilde{X}; X)$ unter Berücksichtigung von $I(\tilde{X}; Y)$ minimieren:

$$\mathcal{L}[p(\tilde{x}|x)] = I(\tilde{X}; X) - \beta I(\tilde{X}; Y) \quad (16)$$

- ▶ Für $\beta = 0$ genau ein Cluster
- ▶ Für $\beta \rightarrow \infty$ keine Kompression

Eigenschaften

Lösung des Minimierungsproblems:

$$p(\tilde{x}|x) = \frac{p(\tilde{x})}{Z(x, \beta)} \exp \left(-\beta \sum_y p(y|x) \log \frac{p(y|x)}{p(y|\tilde{x})} \right) \quad (17)$$

mit

$$p(y|\tilde{x}) = \frac{1}{p(\tilde{x})} \sum_x p(y|x)p(\tilde{x}|x)p(x) \quad (18)$$

und

$$\frac{\delta I(\tilde{X}; Y)}{\delta I(\tilde{X}; X)} = \beta^{-1} > 0 \quad (19)$$

Iterative Berechnung

Ist \mathcal{F} minimal, so gelten die drei Gleichungen

$$p(y|\tilde{x}) = \sum_x p(y|x)p(x|\tilde{x}) \quad (20)$$

$$p(\tilde{x}) = \sum_x p(\tilde{x}|x)p(x) \quad (21)$$

$$p(\tilde{x}|x) = \frac{p(\tilde{x})}{Z(x, \beta)} \exp(-\beta D_{KL}[p(y|x) \| p(y|\tilde{x})]) \quad (22)$$

Analog zu Blahut-Arimoto:

$$\min_{p(y|\tilde{x})} \min_{p(\tilde{x})} \min_{p(\tilde{x}|x)} \mathcal{F}[p(\tilde{x}|x); p(\tilde{x}); p(y|\tilde{x})] \quad (23)$$

Iterative Berechnung

Iteration:

$$\begin{cases} p_t(\tilde{x}|x) = \frac{p_t(\tilde{x})}{Z_t(x,\beta)} \exp(-\beta d(x, \tilde{x})) \\ p_{t+1}(\tilde{x}) = \sum_x p(x) p_t(\tilde{x}|x) \\ p_{t+1}(y|\tilde{x}) = \sum_x p(y|x) p_t(x|\tilde{x}) \end{cases} \quad (24)$$

konvergiert zu einem Minimum von \mathcal{F} ;
Eindeutigkeit ist nicht garantiert!

Anwendungen

- ▶ document clustering
- ▶ neural codes
- ▶ vgl. *Schneidman et. al. 2001*