

# Zufällige Markov-Felder und Gibbs-Potentiale

Benjamin Mayer

Universität Ulm

15. Mai 2006



## – Inhalt

- Motivation
- Anwendungsbeispiele
- Markov-Felder
- Gibbs-Potentiale
- Gibbs-Markov-Äquivalenz
- Inverse Probleme

- Wieso sind zufällige Markov-Felder wichtig in der Bildanalyse?
  - *Problem*: Gemeinsame Verteilung eines Bildes bestimmen
  - Ansatz zur Bestimmung meist unklar
  - *Ausweg*: Annäherung der Bildausgabe durch bedingte Verteilungen
  - Dadurch lässt sich der Aufwand zur Bearbeitung eines Bildbereiches reduzieren
  - Konzentration auf die Nachbarn des zu untersuchenden Datenpunktes (Pixel)




- Beispiele für ein zu untersuchendes Bild



*Abbildung:* Zeitungsausschnitt in invertierter Darstellung

# Zufällige Markov-Felder und Gibbs-Potentiale

- Beispiele für ein zu untersuchendes Bild




*Abbildung:* Graustufenbild, offenporiger Schaumstoff, Bild des Gehirns mit CT

– Was ist ein Zufallsfeld?

- Sei  $S$  eine endliche Menge mit Elementen  $s$ , die als Stellen oder Pixel bezeichnet werden
- Sei  $\Lambda$  eine endliche Menge, die als Phasenraum bezeichnet wird
- Eine Folge  $X = \{X(s) : s \in S\}$  von Zufallsvariablen mit Werten im Phasenraum  $\Lambda$  heißt dann ein *Zufallsfeld*

– Was ist ein Nachbarschaftssystem?

- Ein *Nachbarschaftssystem* auf  $S$  ist eine Familie  $N = \{N_s : s \in S\}$  von Teilmengen von  $S$ , so dass für alle  $s \in S$  gilt
  - 1  $s \notin N_s$
  - 2  $t \in N_s \Rightarrow s \in N_t$
- Sind die Pixel  $s$  und  $t$  Nachbarn, so schreiben wir  $s \sim t$



- Was ist ein Nachbarschaftssystem?
  - Eine Teilmenge  $N_s$  von  $S$  heißt Nachbarschaft des Pixels  $s$
  - Das Tupel  $(S, N)$  heißt *Topologie*
  - In der Interpretation dieses Tupels ist  $S$  die Menge der zu untersuchenden Pixel und  $N$  die vereinigte Menge der Nachbarschaftssysteme aller Pixel  $s \in S$

## – Markovsche Eigenschaft

- Sei  $X_0, X_1, \dots : \Omega \rightarrow E$  eine Folge von Zufallsvariablen, die demselben Wahrscheinlichkeitsraum  $(\Omega, \Sigma, P)$  angehören und ihre Werte in  $E = \{1, 2, \dots, l\}$  annehmen
- Dann heißt die Folge  $\{X_n\}$  von Zufallsvariablen eine *Markovkette*, wenn gilt

$$P(X_n = i_n | X_{n-1} = i_{n-1}, \dots, X_0 = i_0) = P(X_n = i_n | X_{n-1} = i_{n-1})$$

für beliebige  $n = 0, 1, 2, \dots$  und  $i_0, i_1, \dots, i_n \in E$

## – Markovsche Eigenschaft

- Die bedingte Verteilung des (zufälligen) Zustandes  $X_n$  der Markovkette  $\{X_n\}$  zum „Zeitpunkt“  $n$  wird vollständig durch den Zustand  $X_{n-1} = i_{n-1}$  zum vorhergehenden Zeitpunkt  $n-1$  bestimmt
- Eine Verallgemeinerung der Markovschen Kette ins zweidimensionale wird als *Markovsches Feld* bezeichnet
- Die bedingte Wahrscheinlichkeit eines Pixels oder Datenpunkts in einem Gitter, beispielsweise ein Bild, wird also nur durch die Zustände der unmittelbaren Nachbarn bestimmt

## – *Zufaelliges Markov – Feld (MRF)*


- Ein Zufallsfeld  $X$  heißt *zufaelliges Markov – Feld bezueglich* eines Nachbarschaftssystems  $N$ , wenn für alle Pixel  $s \in S$  die Zufallsvariablen  $X(s)$  und  $X(S \setminus N_s \cup \{s\})$  zu gegebenem  $X(N_s)$  unabhängig sind

## – Zufälliges Markov-Feld


- Ein Zufallsfeld  $X$  ist ein Markov-Feld, wenn

$$P(x_s | \{x_t, t \neq s\}) = P(x_s | \{x_t, t \in N_s\})$$

- Mit anderen Worten: Die Wahrscheinlichkeit, dass der Pixel  $s$  einen bestimmten Wert annimmt hängt ausschließlich von den Werten der Nachbarn  $t$  ab mit  $t \in N_s$



- Beispiele für Markov'sche Felder



– Lokale Charakteristik von  $P$


- Das Wahrscheinlichkeitsmaß  $P$  sei strikt positiv, d.h.  $P(x) > 0$ ,  $x \in X$
- Bedingte Wahrscheinlichkeiten der Form

$$P(X_A = x_A | X_{S \setminus A} = x_{S \setminus A}), \quad A \subset S,$$

heißen lokale Charakteristiken von  $P$

- gibt die Wahrscheinlichkeit an, dass  $x_A = (x_s)_{s \in A}$  eine Struktur in  $A$  ist unter der Bedingung, dass  $x_{S \setminus A} = (x_s)_{s \in S \setminus A}$  für den Rest der Umgebung gilt

- Zusammenhang Lokale Charakteristik und Markov'sche Eigenschaft
  - der Zustand des Pixels  $s$  ist abhängig von den Zuständen seiner *unmittelbaren* Nachbarn  $t \in N_s$



– Local Specifications (lokale Bestimmtheiten)

- Die lokale Charakteristik auf einem MRF an der Stelle  $s$  ist gegeben durch die Funktion

$$\pi^s(x) = P(X(s) = x(s) | X(N_s) = x(N_s))$$

- Die Familie  $\{\pi^s\}_{s \in S}$  heißt local specification oder die lokale Bestimmtheit des MRF

## – Gibbs-Feld

- Eine spezielle Klasse von Zufallsfeldern sind die *Gibbs – Felder*
- Das Gibbs-Feld ist charakterisiert durch die analytische Darstellung der Wahrscheinlichkeitsverteilung

## – *Potential*

- Ein Potential ist eine Familie  $\{U_A : A \subset S\}$  von *Funktionen* in  $X$
- Für die Familie  $\{U_A : A \subset S\}$  gilt
  - 1  $U_\emptyset = 0$
  - 2  $U_A(x) = U_A(y)$ , wenn  $x_s = y_s \ \forall s \in A$
- Die Energie von  $U$  ist gegeben durch

$$H_U(x) = \sum_{A \subset S} U_A(x)$$

- Hierbei sei  $x$  der Gitterpunkt eines Bildes, der den Zustand  $s$  beschreibt,  $A \subset S$  sei eine Teilmenge aller Pixel in  $S$

## – Gibbs – Verteilung

- Ein Zufallsfeld  $X$  ist ein Gibbs-Feld der Energie  $H_U(x) = \sum_{A \subset S} U_A(x)$ , wenn  $X$  von der sogenannten *Gibbs – Verteilung*

$$\Pi(x) = P(X = x) = \frac{1}{Z} * \exp(-H_U(x))$$

beherrscht wird

## – Gibbs-Verteilung

- $Z$  ist hierbei eine Normierungskonstante, die aus  $P$  ein Wahrscheinlichkeitsmaß macht
- $Z$  lässt sich oftmals weder analytisch noch numerisch bestimmen aufgrund der großen Anzahl möglicher Strukturen
- Jede Verteilung eines Zufallsfeldes kann in der Form  $\Pi(x)$  dargestellt werden

- Die spezielle Rolle der Gibbs-Felder
  - Sei  $\mu$  eine beliebige Wahrscheinlichkeitsverteilung auf einem Zufallsfeld  $X$
  - Die Information, die wir durch die Beobachtung  $x \in X$  erhalten, wird gemessen durch die Zahl  $-\ln\mu(x)$
  - Man betrachtet den mittleren Informationsgehalt einer Beobachtung  $x \in X$ , die sogenannte *Entropie*, durch  $\Phi(\mu) = -\sum_x \mu(x)\ln\mu(x)$  und die mittlere Energie  $E(H; \mu) = \sum_x H(x)\mu(x)$  von  $\mu$

- Die spezielle Rolle der Gibbs-Felder
  - Es gilt  $E(H; \mu) - \Phi(\mu) \geq \ln Z$
  - Diese Ungleichung ist in der statistischen Physik bekannt als das *Gibbs variational principle*
  - $Z$  ist hierbei die Normierungskonstante der Gibbs-Verteilung
  - Das *Gibbs variational principle* bedeutet, dass das Gibbs-Feld  $\Pi$  die größte Entropie  $\Phi(\mu)$  hat unter allen Verteilungen

## – *Clique*

- Eine Teilmenge  $C \subset S$  heißt für  $c \in C$ ,  $c \geq 2$ , eine Clique der Topologie  $(S, N)$  genau dann, wenn zwei beliebige verschiedene Elemente  $c_1, c_2 \in C$  gegenseitige Nachbarn sind, d.h. wenn gilt  $c_1 \in N_{c_2}$  und  $c_2 \in N_{c_1}$
- Beispiel für Cliques einer Vierer-Nachbarschaft



## – *Nachbarschaftspotential*

- $U$  heißt *Nachbarschaftspotential bezüglich* eines Nachbarschaftssystems  $N$ , wenn  $U_A = 0$  für alle Teilmengen  $A$  von  $S$ , die *keine* Clique bilden
- Wenn  $U$  kein Nachbarschaftspotential ist, so besitzt das zugehörige Gibbs'sche Zufallsfeld keine Markov'sche Eigenschaft

## – Beispiele für Energien und Potentiale

- Grundlage sei das diskrete Energiemodell

$$H(g|x) = \alpha H_1(g) + H_2(x|g) = \alpha \sum_s (2g(t_s) - g(t_{s-1}) - g(t_{s+1}))^2 + \sum_s (x_s - g(t_s))^2$$

- $x$  sei hierbei das Originalbild
- $t_s$  sind die benachbarten Stellen des Pixels  $s$
- Das Bild ist hierbei eindimensional, sonst wären  $\dots t_{s-1}, t_s, t_{s+1} \dots$  nicht definiert
- $g$  ist eine Annäherung von  $x$ , man sagt  $g$  ist ein *Spline*
- $H_1$  misst die lokale Abweichung der diskretisierten Oberfläche  $g$

## – Krümmungsenergie

- Wir betrachten den Term  $H_1$  und schreiben ihn etwas um in

$$H_1(g) = \sum_s (2g(t_{s+1}) - g(t_s) - g(t_{s+2}))^2$$

- Es gilt hier  $x \equiv g$  mit  $S = \{t_1, \dots, t_n\}$  und  $t \in \mathbb{R}$
- Man erhält  $H_1(g) = \sum_s (6g(t_s)^2 - 4g(t_s)g(t_{s+1}) + g(t_s)g(t_{s+2}))$
- $H_1$  ist ein Nachbarschaftspotential und beschreibt die Glattheit der Annäherung
- $\alpha$  ist ein Kontrollparameter für den Einfluss der Glattheit auf das Modell
- $g$  kann als Realisierung eines Markov-Feldes  $X$  aufgefasst werden mit der Gibbs-Verteilung

$$P(X = g) = \frac{1}{Z} * \exp(-\alpha H_1(g))$$

## – Bernoulli Energie

- $X$  sei ein binäres Markov-Feld mit  $S \subset \mathbb{Z}^2$  und Werten in  $\Lambda = \{0, 1\}$
- Das Nachbarschaftssystem von  $s$  sei das der vier nächsten Nachbarn
- $t_s$  ist genau dann ein Nachbar von  $s$ , wenn  $\|s - t\|_2 = 1$
- Die Cliques sind die Pixel  $s$  und die Paare  $s \sim t$ , so dass  $\|s - t\|_2 = 1$
- $X$  heißt ein Bernoulli Feld mit der folgenden Gibbs-Verteilung

$$P(X = x) = \frac{1}{Z} * \exp(-H(x))$$

und es gilt

$$H(x) = \alpha_1 \sum_s x_s + \alpha_2 \sum_{\langle s, t \rangle} x_s x_t$$

## – Gauß Energie

- Das Nachbarschaftssystem von  $s$  sei wiederum das der vier nächsten Nachbarn
- Wir benutzen  $\Lambda$ , um ein diskretes symmetrisches Intervall anzugeben
- Ein Markov-Feld mit diesem Nachbarschaftssystem heißt ein zentriertes Gauß-Feld und ist gegeben durch die folgende Gibbs-Verteilung

$$P(X = x) = \frac{1}{Z} * \exp(-H(x))$$

mit


$$H(x) = \alpha_1 \sum_s x_s^2 + \alpha_2 \sum_{\langle s,t \rangle} x_s x_t$$

## – Ising Modell

- Modell für binäre Bilder (schwarz - weiß)
- Testmodell für grundlegende Fragen über Markov-Felder
- Beschreibt verschiedene fundamentale und typische Phänomene, die in vielen komplexen Systemen vorkommen (z. B. Ferromagnetismus, Metalllegierungen)

## – Ising Modell

- $S = \mathbb{Z}^2$ ,  $\Lambda = \{+1, -1\}$  im endlichen Modell
- Das Nachbarschaftssystem  $N$  ist das der vier nächsten Nachbarn



- Die vollständig bedingte Dichte ist gegeben durch

$$P(x_s = 1 | x(N_s)) = \frac{\exp(\beta n_s^b)}{\exp(\beta n_s^b) + \exp(\beta n_s^w)}$$

## – Ising Modell

- $\beta$  ist ein positiver Parameter
- $n_s^b = \sum_{t \sim s} 1_{[x_t=1]}$ : Anzahl der schwarzen Nachbarn von  $s$
- $n_s^w = \sum_{t \sim s} 1_{[x_t=-1]}$ : Anzahl der weißen Nachbarn von  $s$
- Die Energiefunktion ist hier im einfachsten Fall gegeben durch

$$H(x) = -\beta \sum_{s \sim t} x_s x_t$$

## – Potts Modell

- Verallgemeinerung des Ising Modells auf mehr als zwei Farben
- $x_s \in \{0, 1, 2, \dots, n_c - 1\}$ , Anzahl der Farben  $n_c > 2$
- Die Farben sind nicht geordnet
- Die Energiefunktion ist gegeben durch

$$H(x) = -\gamma \sum_{s \sim t} \delta_{x_s, x_t}$$


mit

$$\delta_{a,b} = 1, \text{ wenn } a = b \text{ und } \delta_{a,b} = 0 \text{ sonst}$$

- Das Ising Modell ist also ein Spezialfall des Potts Modells für zweifarbige Bilder

# Zufällige Markov-Felder und Gibbs-Potentiale

– Ising Modell und Potts Modell



*Abbildung*: oben links: kleines  $\beta$ , unten links: großes  $\beta$

## – Binäre auto-logistik Modelle

- Jeder Term im Ising Modell kann individuell gewichtet werden, so dass

$$H(x) = \sum_{s \sim t} \vartheta_{st} x_s x_t + \sum_s \vartheta_s x_s$$

mit  $x_s = \pm 1$

- Wenn  $\vartheta_{st} < 0$  gilt ist  $x_s = x_t$  zu favorisieren
- Umgekehrt unterstützt  $\vartheta_{st} > 0$  die These  $x_s = -x_t$

- Gibbs-Markov-Äquivalenz
  - Die Gibbs-Markov-Äquivalenz besteht aus zwei Teilen
  - Der direkte Teil liefert die Aussage: Gibbs-Felder sind Markov-Felder
  - Der andere (theoretische) Teil ist durch den Satz von Hammersley-Clifford gegeben
  - Zusammen mit dem direkten Teil kann man aus Hammersley-Clifford folgern, dass Gibbs-Verteilungen und MRFs im Wesentlichen dieselben Objekte sind

- Gibbs-Felder sind Markov-Felder
  - Sei  $X$  ein Gibbs-Feld des Potentials  $U$ . Wenn  $U$  ein Nachbarschaftspotential bezüglich eines Nachbarschaftssystems  $N$  ist, so ist  $X$  ein Markov-Feld bezüglich desselben Nachbarschaftssystems

– Satz von Hammersley-Clifford

- Sei  $P$  die Verteilung eines zufälligen Markov-Feldes bezüglich einer Topologie  $(S, N)$ , wobei  $P$  strikt positiv sei. Dann gilt

$$P(x) = \frac{1}{Z} * \exp(-H_U(x))$$

in Verbindung mit der Topologie  $(S, N)$  für eine Energiefunktion  $H(x)$ , die von einem Gibbs-Potential  $\{U_A : A \subset S\}$  abstammt

## – Inverse Probleme

- direktes Problem: man ermittelt aus bekannten Ursachen die unbekanntes Wirkungen, d.h. beispielsweise wie verändert sich ein Bild, das aufgrund bekannter Ursachen bei der Übertragung gestört wird
- inverse Problemstellung: gegeben sind Beobachtungen der Wirkungen (ein übertragenes Bild) und gesucht sind die Ursachen
- Die gesuchten Größen lassen sich meist nicht direkt messen
- Vereinfacht gilt im inversen Problem: Wirkung  $\implies$  Ursache

## – Inverse Probleme

- Bisher verstanden wir das Zufallsfeld  $X$  als direkt beobachtbar
- Tatsächlich ist  $X$  jedoch in den meisten Situationen der Bildanalyse nicht direkt beobachtbar
- Man nennt ein Zufallsfeld  $X$  versteckt, wenn es nicht „physisch“ beobachtbar ist

## – Inverse Probleme

- Die Definition eines inversen Problems ist bei *Bernard Chálmoud* zusammengefasst durch die geordnete Dreiergruppe  $(y^\circ, X, H(x|y, \theta))$ 
  - ① Das erste Element ist ein beobachtetes Feld  $y^\circ$  auf einem Gitter  $\tilde{S}$
  - ② Das zweite Element  $X$  ist die Definition eines versteckten Zufallsfeldes auf einem Gitter  $S$ , wobei  $S$  nicht notwendigerweise identisch mit  $\tilde{S}$  sein muss
  - ③ Das dritte Element ist die Definition einer Energiefunktion, dargestellt durch

$$H(x|y, \theta) = H_1(x, \theta_1) + H_2(y, \theta_2)$$

Die Energiefunktionen  $H_1$  und  $H_2$  sind Energien eines Nachbarschaftspotentials und  $\theta_{i,j}$  sind Parameter zur Gewichtung

- Die Zerlegung der Energiefunktion  $H$  ist additiv, dies folgt aus der a-posteriori-Wahrscheinlichkeit
- Die Lösung dieses inversen Problems bringt die Berechnung des Minimums einer definierten Kostenfunktion mit sich gemäß  $H(x|y^\circ, \theta)$

– Beispiel eines inversen Problems

- In der numerischen Differentiation wird die Ableitung einer Funktion  $f$  im Punkt  $x_0$  gesucht, bekannt sind die Funktionswerte
- Die Ableitung lässt sich bestimmen mittels Differenzenquotient

$$f'(x_0) = \lim_{x \rightarrow x_0} \frac{f(x) - f(x_0)}{x - x_0}$$

- Ersetzung des Grenzwertes durch die Wahl eines geeigneten Punktes  $x$

## – Zusammenfassung und Ausblick

- Problemstellung der Bildanalyse (Bestimmung einer gemeinsamen Verteilung eines Bildes) wird vereinfacht durch MRF's
- Aufwand zur Bearbeitung eines Bildes wird reduziert
- Anwendung in vielen Bereichen (Medizin, Technik, Kommunikation)
- Anwendungen stochastischer Bildmodelle als nächstes Thema

## – Literatur

- Gerhard Winkler „Image Analysis, Random Fields and Markov Chain Monte Carlo Methods“
- Bernard Chálmoud „Modeling and Inverse Problems in Image Analysis“
- Jesper Møller „Spatial Statistics and Computational Methods“
- Pierre Brémaud „Markov Chains, Gibbs Fields, Monte Carlo Simulation and Queues“
- Volker Schmidt „Markov Ketten und Monte Carlo Simulation“
- Arnd Rösch „Inverse Probleme“, TU Berlin
- <http://www.google.de>, <http://www.wikipedia.org>