

# Statistická analýza obrazu a kontrola jakosti

## ROBUST 2012

David Legát

MFF UK

14. září 2012

# Obsah

- 1 Úvod
- 2 Předzpracování obrazu
- 3 Perfect sampling
- 4 Isingův model
- 5 Klasifikace obrazu
- 6 Kontrola jakosti

# Úlohy analýzy obrazu

- Předzpracování obrazu
  - Redukce šumu v obrazu
  - Segmentace obrazu
  - Detekce hran v obrazu
- Klasifikace obrazu
  - Zařazení obrazu do vhodné třídy
  - Identifikace objektů v obrazu
- Aplikace analýzy obrazu
  - Detekce obličejů v obrazu
  - Převádění ručně vyplňovaných formulářů do elektronické podoby
  - Analýza satelitních snímků povrchu Země
  - Identifikace vad v materiálech

# Odstanění šumu z obrazu

Vztah pro podmíněné rozdělení původního obrazu  $\mathbf{x}$ , při pozorovaném  $\mathbf{y}$  získáme z Bayesovy věty:

$$P(\mathbf{x} | \mathbf{y}) = \frac{\Pi(\mathbf{x})P(\mathbf{y}|\mathbf{x})}{\sum_{\mathbf{z} \in \mathcal{O}} \Pi(\mathbf{z})P(\mathbf{y}|\mathbf{z})}$$

- $\mathcal{O}$  značí prostor všech obrazů.
- Pro apriorní rozdělení  $\Pi(\mathbf{x})$  původního obrazu  $\mathbf{x} \in \mathcal{O}$  často volíme některý ze základních představitelů náhodných polí (Isingův model; Pottsův model).
- Podmíněné pravděpodobnosti  $P(\mathbf{y}|\mathbf{x})$  závisí na způsobu zašumění původního obrazu.

# MCMC simulace

## Úloha

- Konečná množina stavů  $\mathcal{S} = \mathcal{S}_1 \times \cdots \times \mathcal{S}_N$
- Pravděpodobnostní rozdělení  $\Pi$  na množině  $\mathcal{S}$
- **Úloha:** Vygenerovat posloupnost  $\{X_i\}_{i \in \mathbb{N}_0}$  reprezentující  $\Pi$

## Metropolisův-Hastingsův algoritmus

- Vygeneruj nový prvek  $x'_{k+1}$  z rozdělení  $Q(x|x_k)$ .
- Akceptuj  $x_{k+1} = x'_{k+1}$  s pravděpodobností  $\alpha(x'_{k+1}, x_k)$ ,  
jinak  $x_{k+1} = x_k$ .

$$\alpha(r, s) = \min \left( 1, \frac{\Pi(r)Q(r|s)}{\Pi(s)Q(s|r)} \right), \quad r, s \in \mathcal{S}$$

## Gibbsův algoritmus

- Vyber složku vektoru  $i \in \{1, \dots, N\}$ .
- Vygeneruj novou hodnotu  $x_{k+1}^{(i)}$  z podmíněného rozdělení  
 $\Pi(X^{(i)} = x_{k+1}^{(i)} | X^{(-i)} = x_k^{(-i)})$

# Markovovy řetězce

## Podmínka reversibility

$$\Pi(r)\mathbf{P}(s|r) = \Pi(s)\mathbf{P}(r|s) \quad \forall r, s \in \mathcal{O}$$

- $\mathbf{P}(s|r)$  – pravděpodobnost, že v jednom kroku MCMC simulace přejdeme z obrazu  $r$  na obraz  $s$
- Podmínka reversibility  $\Rightarrow \Pi(x), x \in \mathcal{S}$  je stacionární rozdělení generovaného řetězce

## Nerozložitelný, aperiodický na konečné množině stavů

$$\nu P^n \longrightarrow \Pi$$

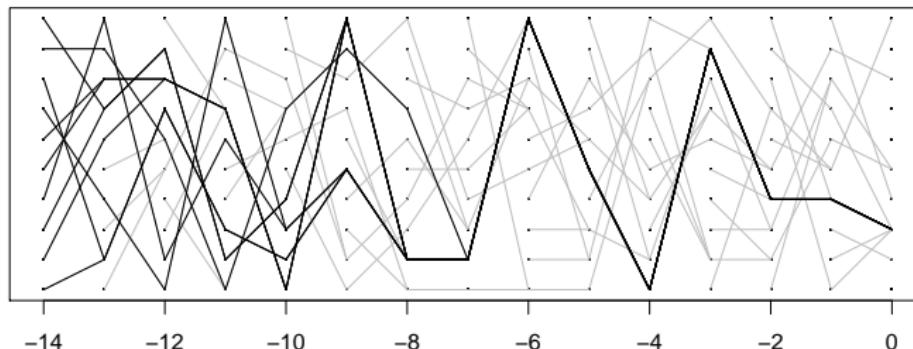
- $\nu$  – Rozdělení prvního prvku  $X_0$  posloupnosti
- $P^n$  – Pravděpodobnosti přechodu  $n$  kroků MCMC simulace

# Coupling from the past

- Pro jak velké  $n$  je  $\nu P^n$  dostatečně blízko k  $\Pi$ ?
- Jak generovat stacionární řetězec? Tj.  $\nu = \Pi$ .

# Coupling from the past

- Pro jak velké  $n$  je  $\nu P^n$  dostatečně blízko k  $\Pi$ ?
- Jak generovat stacionární řetězec? Tj.  $\nu = \Pi$ .



- Jdeme zpět v čase.
- Pro každý krok si pamatujeme přechody ze všech stavů.
- Dojde-li ke splynutí všech stavů do jednoho, potom dostaneme stacionární rozdělení  $\Pi$ .

# Stochastické proudy (stochastic flows)

## Náhodné zobrazení

- Náhodná veličina  $\varphi$  na pravděpodobnostním prostoru  $(\Phi, \mathbb{P})$ ,
  - kde  $\Phi = \{\varphi : S \rightarrow S\} \equiv S^S$ .
- $\varphi$  je náhodné zobrazení vzhledem k matici přechodů  $P$ , když

$$\mathbb{P}(\{\varphi : \varphi(r) = s\}) = p(s|r), \quad \forall r, s \in S. \quad (\text{P})$$

## Stochastický proud

- Náhodná veličina  $\bar{\varphi}$  na prostoru oboustranných posloupností náhodných zobrazení  $\Omega = \Phi^{\mathbb{Z}}$

$$\bar{\varphi} = \{\varphi_j\}_{j \in \mathbb{Z}} = (\dots, \varphi_{j-1}, \varphi_j, \varphi_{j+1}, \dots).$$

- Prostor  $\Omega$  vybaven součinnovou pravděpodobnostní mírou  $\bar{\mathbb{P}}$

$$\bar{\mathbb{P}}(\{\bar{\varphi} \in \Omega : \varphi_i = \psi_i, i \in I\}) = \prod_{i \in I} \mathbb{P}(\psi_i).$$

- Značíme  $\varphi_{n+1}^{n+m} = \varphi_{n+m} \circ \dots \circ \varphi_{n+1}$

# Splynutí stavů

## Kompletní splynutí v čase $n$

- Uvažujme jednu posloupnost zobrazení  $\bar{\varphi} \in \Omega$

$$\exists k \in \mathbb{N}^0, \exists \omega \in \mathcal{S}, \forall s \in \mathcal{S} \quad \varphi_{n-k}^n(s) = \omega.$$

## Kompletní splynutí skoro jistě

- $F_n$  množina všech proudů s kompletním splynutím v čase  $n$

$$\mathbb{P}(F) = 1. \tag{F}$$

kde  $F = \bigcap_{n \in \mathbb{Z}} F_n$ .

# Splynutí stavů

Vlastnosti stochastických proudů:

- (P)  $\{\varphi_j\}_{j \in \mathbb{Z}}$  jsou náhodná zobrazení vzhledem k matici přechodů  $P$ .
- (F) Nastává kompletní splynutí skoro jistě.

Stav splynutí

$$W_n(\bar{\varphi}) = \begin{cases} \lim_{m \rightarrow -\infty} \varphi_m^n(s), & s \in S, \quad \bar{\varphi} \in F_n, \\ \omega_0, & \text{jinak,} \end{cases}$$

**Věta:**

Za podmínek (P) a (F) je náhodný proces  $\{W_n\}_{n \in \mathbb{Z}}$  stacionární homogenní Markovův řetězec s maticí přechodů  $P$ .

# Jak simuloval náhodná zobrazení

## Obecný princip

- Uvažujme
  - funkci  $f : S \times \Theta \rightarrow S$
  - iid  $U_i, i \in \mathbb{Z}$  s hodnotami v  $\Theta$ .
- Pak  $\varphi_i = f(\cdot, U_i)$  je náhodné zobrazení

## Běžná konstrukce

$$\Theta = \langle 0, 1 \rangle \text{ a } U_i \sim U(\langle 0, 1 \rangle)$$

$$f(s_i, u) = s_1 \quad \text{if } u \in [0, p(s_i, s_1)]$$

$$f(s_i, u) = s_2 \quad \text{if } u \in (p(s_i, s_1), p(s_i, s_1) + p(s_i, s_2)]$$

$$\vdots$$

$$\vdots$$

$$f(s_i, u) = s_n \quad \text{if } u \in (1 - p(s_i, s_n), 1].$$

# Jak ověřit podmínu (F)

## Definice:

Nechť  $\bar{\varphi} \in \Omega$  je stochastický tok. Pak náhodná veličina

$$T_n(\bar{\varphi}) = \sup\{m \leq n : \exists \omega \in S \text{ such that } \varphi_m^n(s) = \omega \forall s \in S\}$$

je nazývána čas *nejpozdějšího splynutí* před časem  $n$ .

## Věta:

Nechť  $(\Omega, \bar{\mathbb{P}})$  je prostor stochastických toků. Pak následující podmínky jsou všechny ekvivalentní podmínce (F)

- 1)  $\bar{\mathbb{P}}\{\bar{\varphi} \in \Omega : T_n(\bar{\varphi}) > -\infty\} = 1 \quad \forall n \in \mathbb{Z}$
- 2)  $\exists \tau \in \mathbb{N}$  takové, že  $\bar{\mathbb{P}}\{\bar{\varphi} \in \Omega : T_0(\bar{\varphi}) > -\tau\} > 0$
- 3)  $\forall r, s \in S \exists n_{rs} \in \mathbb{N}$  tak, že  
 $\bar{\mathbb{P}}\{\bar{\varphi} \in \Omega : \varphi_1^{n_{rs}}(r) = \varphi_1^{n_{rs}}(s)\} > 0$

# Částečně uspořádané množiny stavů

## Definice:

Částečné uspořádání na množině  $S$  je relace  $r \preceq s$  mezi prvky  $r, s \in S$  se dvěma vlastnostmi

- **reflexivita** -  $s \preceq s \quad \forall s \in S$
- **transitivita** -  $r \preceq s$  a  $s \preceq t$  implikuje  $r \preceq t$

## Definice:

Říkáme, že náhodné zobrazení  $\varphi = (\Phi, \mathbb{P})$  zachovává uspořádání skoro jistě, jestliže platí

$$\mathbb{P}(\Gamma) = 1, \tag{M}$$

kde  $\Gamma = \{\varphi \in \Phi : r \preceq s \Rightarrow \varphi(r) \preceq \varphi(s), \forall r, s \in S\}$

# Splynutí extrémů

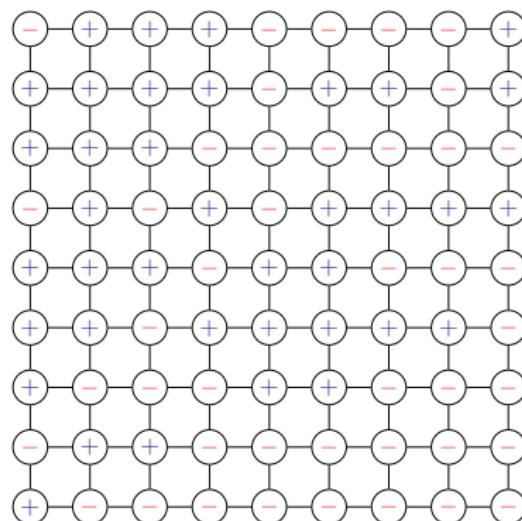
## Věta:

Předpokládejme, že  $\mathbf{P}$  je jádro nerozložitelného Markovova řetězce na částečně uspořádané množině stavů  $(S, \preceq)$  takové, že existují minimální a maximální stavy  $\underline{m}, \overline{m} \in S$  a

$$r \preceq s \text{ and } s \preceq r \Leftrightarrow r = s, \quad \forall r, s \in S.$$

Mějme dále prostor  $(\Phi, \mathbb{P})$  náhodných zobrazení, který splňuje podmínu (F) a (M). Nechť  $(\Omega, \bar{\mathbb{P}})$  je prostor náhodných toků složených z náhodných zobrazení  $\Phi$  (tj.  $\Omega = \Phi^{\mathbb{Z}}$  a  $\bar{\mathbb{P}}$  je součinová míra  $\mathbb{P}^{\mathbb{Z}}$ ). Pak splynutí extrémů  $\underline{m}, \overline{m}$  je postačující podmínkou pro úplné splynutí.

# Jak vypadá Isingův model?



- Obraz  $\mathbf{y} = \{y_b \in \mathcal{G}\}_{b \in B}$
  - $B$  – pravoúhlá mřížka bodů  

$$B = \{(i, j) \in \mathbb{N}^2, i \leq N, j \leq M\}$$
  - $\mathcal{G}$  – množina možných intezit
  - Isingův model černobílého obrazu
- $$\Pi(\mathbf{y}) \sim \exp \left( \beta \sum_{a \sim b} y_a y_b \right)$$
- $\mathcal{G} = \{-1, 1\}$
  - $a \sim b$  značí sousední body v mřížce
  - Energie obrazu  $E = -\beta \sum_{a \sim b} y_a y_b$

# Swendsonův–Wangův algoritmus

Gibbsův a Metropolisův–Hastingsův algoritmus:

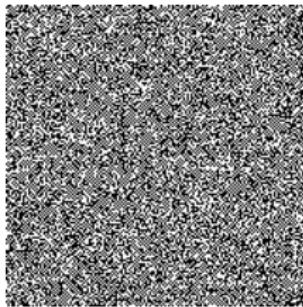
- Obměňují v každém kroku pouze jeden bod.
- Přechod od tmavého obrazu ke světlému je nepravděpodobný pro vysoké hodnoty parametru  $\beta$ .

Swendsonův–Wangův algoritmus:

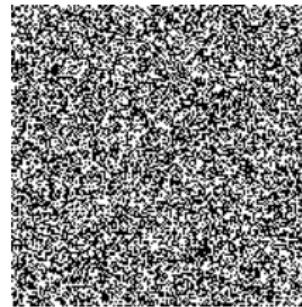
- Generuje nejenom sekvenci obrazů  $\{x_i\}_{i \in \mathbb{N}}$ , ale také sekvenci mikrohran  $\{e_i\}_{i \in \mathbb{N}}$ .
- V každém kroku může změnit všechny body obrazu.
- Konverguje rychleji ke rozdělení Isingova modelu.
- V každém kroku provede dva úkony:
  - Nastavení mikrohran
  - Volba nového obrazu

# Příklady Isingova modelu

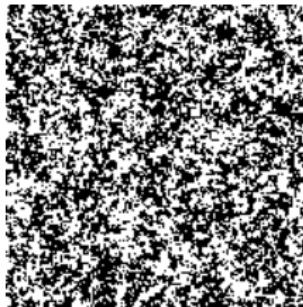
$\beta = -0.3$



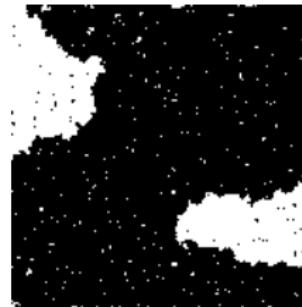
$\beta = 0$



$\beta = 0.3$

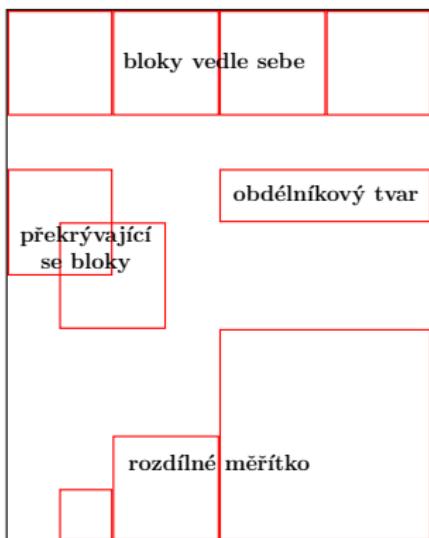


$\beta = 0.6$



# Klasifikace obrazu

## Rozdělení obrazu na bloky



- Postup klasifikace

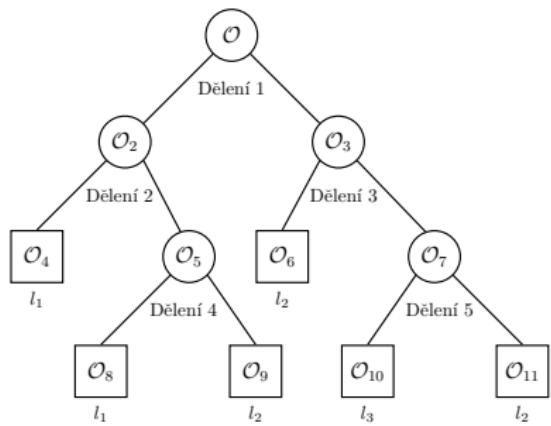
- Rozdělit obraz na bloky
- Každému bloku přiřadit texturu

- Bayesovský přístup

- Pottsův, případně Isingův model volen jako apriorní rozdělení textur

- Zkoumaných bloků je zpravidla mnoho, proto záleží nejenom na přesnosti použitého klasifikátoru, ale také na rychlosti klasifikace.

# Klasifikační stromy



- Časová náročnost  $W(t)$  listu  $t$  je časem potřebným pro spočtení charakteristik v děleních nad ním.
- Střední časová náročnost stromu  $T$  je vážený průměr

$$W(T) = \sum_{t \in \mathcal{T}} W(t) P(\mathbf{Y} \in \mathcal{O}_t).$$

Zohlednění střední časové náročnosti stromu při učení klasifikátoru

- Modifikace kritéria pro volbu vhodného dělení
- Nová zastavovací pravidla
- Zohlednění střední časové náročnosti při prořezávání stromu

# Identifikace vad ve tkaných textiliích

## Popis problému

- Vizuální kontrola textilií je časově náročná a v případě malých vad i nepřesná.
- Při automatické detekci vad je nasnímán obraz látky.
- Klasifikační algoritmus musí být kalibrován pro konkrétní stroj na detekci vad.

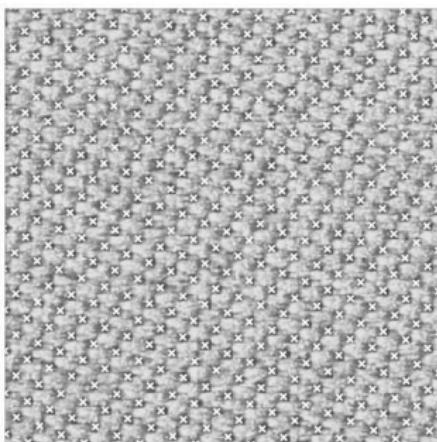
### Vady podle směru:

- ve směru osnovy
- ve směru útku
- směrově nezávislé

### Vady podle závažnosti:

- nezávažné – stačí vyznačit místo výskytu
- závažné – potřeba zastavit stroj a opravit vadu

# Popis látky bez vad



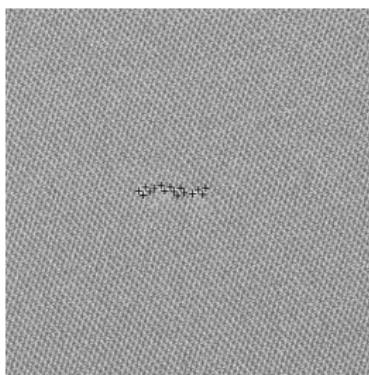
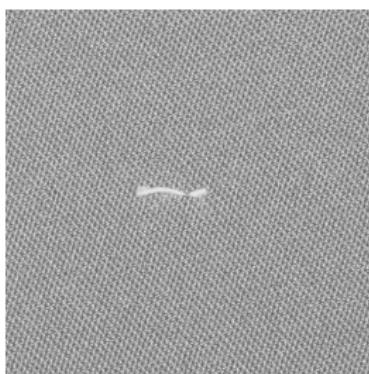
## Základní body

- Středy tmavých oblastí v obrazu
- Obraz aproximován pomocí diskrétní Fourierovy transformace

## Popis obrazu látky bez vad

- Vzájemná poloha sousedních základních bodů ve směru útku
- Vzájemná poloha sousedních základních bodů ve směru osnovy
- Vzhled obrazu látky v okolí základních bodů

# Identifikace vad



## Identifikace vad

- Postupně procházíme kandidáty na základní body.
- Vyznačíme vadu, když se zvolený výřez výrazně liší od průměrného okolí základních bodů v látce bez vad.

## Klasifikace vad

- Každé identifikované vadě manuálně přiřadíme její typ.
- Máme-li pro nějaký typ vady dostatečné množství vzorků, vytvoříme model pro jeho rozpoznání.

Děkuji...

# Literatura

- ① Fieguth P. (2011): Statistical Image Processing and Multidimensional Modeling. Springer, New York.
- ② Hastings W.K. (1970): Monte Carlo sampling methods using Markov chains and their applications. Biometrika 57, 97–109.
- ③ Roberts, Ch. P., Casella, G.(2005): Monte Carlo Statistical Methods, Springer, Heidelberg.
- ④ Breiman, L., Friedman, J. H., Olshen, R. A. a Stone, C. J. (1984): Classification and Regression Trees. Wadsworth & Brooks/Cole Advanced Books & Software, Monterey.
- ⑤ Linka, A., Volf, P. (2001): Statistické metody pro hodnocení homogeneity textilních materiálů. ROBUST'2000, JČMF, 2001, 164–175.
- ⑥ Tunák, M. (2011): Detekce vad v plošných textiliích. Disertační práce, Technická univerzita v Liberci.