

Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

1. Úvod.
2. Řídicí strategie.
3. Rozpoznávání.
4. Analýza histogramu.
5. Metody díl po dílu.
6. Metody křížení dílů.
7. RANSAC.

Porozumění obsahu obrazu

Karel Horák




Rozvrh přednášky:

- 1. Úvod.**
2. Řídicí strategie.
3. Rozpoznávání.
4. Analýza histogramu.
5. Metody díl po dílu.
6. Metody křížení dílů.
7. RANSAC.





Úvod – motivace

- ▶ Proč je porozumění obrazu těžké:
 - snaha řešit biologické úlohy technicky
 - obráceně: technické inspekční systémy pro průmyslové aplikace jsou přesnější a spolehlivější, než biologická kontrola
- ▶ Interpretace obecného obrazu – jaké město je na obrázku?



Úvod – motivace

- ▶ Biologický přístup:
 - jak víme, že jde o Paříž, když jsme ji nikdy neviděli z tohoto místa?
 - analogie + generalizace = biologická klasifikace
- ▶ Technický přístup:
 - extrakce příznaků, klasifikace objektů
 - malá množina srovnávacích modelů



Úvod – příklad


- ▶ Biologický vs. technický přístup – příklad 1:
 - úloha = detekovat známe osoby v davu
 - postup: segmentace objektů → rozpoznání osob → identifikace jedince



(Londýn – letiště Heathrow)

Úvod – příklad





- Biologický vs. technický přístup – příklad 2:
 - úloha: rozpoznat gesto pro řízení procesu popř. upřesnění kontextu situace
 - postup: detekce pohybu → segmentace ruky → klasifikace gesta



Úvod – příklad

► Biologický vs. technický přístup – příklad 3:

- úloha: detekovat vady a klasifikovat vadné výrobky
- postup: jasové korekce → segmentace nehomogenit → klasifikace příznaků



Úvod – interpretace obrazu

► Interpretace výsledků zpracování obrazu:

– silný předpoklad: přesná segmentace + popis vnitřního modelu + správná klasifikace

– slabý závěr: nezaznamenané vlivy okolí (dezinterpretace), statické snímání dynamické scény, ...

► Jakou akci můžeme následně očekávat?



Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

1. Úvod.
- 2. Řídicí strategie.**
3. Rozpoznávání.
4. Analýza histogramu.
5. Metody díl po dílu.
6. Metody křížení dílů.
7. RANSAC.

Řídicí strategie – definice

- ▶ Řídicí strategie vizuálního systému určuje míru porozumění obsahu obrazu:
 - syntaxe zpracování obrazu = definice konkrétních kroků zpracování obrazu
... filtrace šumu, lokalizace kružnic, detekce oblastí tváře, hledání šablony, ...
 - sémantika zpracování obrazu = celkové porozumění obsahu obrazu tj. vnitřnímu modelu
... rozpoznání výrazu tváře, klasifikace strojních dílů, dopravní asistent, ...

- ▶ Řídicí strategie zpracování a porozumění obrazu:
 - hierarchické řízení = lze deklarovat nižší a vyšší úrovně procesu
 - nehierarchické řízení = nelze stanovit úrovně/priority jednotlivých metod, vykonávání procesu je založeno na principu soutěžení

Řídicí strategie – hierarchické řízení

- ▶ Hierarchické řízení (existuje nižší a vyšší úroveň řízení/zpracování):
 - řízení zdola nahoru
 - řízení obrazovými daty
 - postup od rastrového obrazu k popisu a rozpoznání objektů (prvotní přístup)
 - řízení shora dolů
 - řízení podle vnitřního modelu
 - vytvoření apriorní hypotézy o objektu a její následné ověření nebo zamítnutí
 - kombinované řízení
 - využívá znalostí z vyšší úrovně pro řízení operací nižší úrovně
 - např.: úloha hledání kružnic (znalost vyšší úrovně) → volíme Houghovu transformaci pro detekci kružnic (řízení nižší úrovně)
 - znalosti z vyšší úrovně však samy o sobě nestačí k celkovému řešení úlohy → málokdy je použito jen řízení zdola-nahoru nebo shora-dolu

Řídicí strategie – nehierarchické řízení

► Nehierarchické řízení:

- příměr = spolupráce a vzájemné soutěžení odborníků (metod) na řešení úlohy (např. komplexní analýza leteckých snímků)
- strategie nehierarchického řízení: iterativně je vybírán odborník s nejlepší odezvou podle předchozích výsledků
- princip tabule: báze dat přístupná všem odborníkům, mechanismus sdílení
- démon: subsystém okamžitého zásahu do řídicí strategie mechanismem tabule

Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

1. Úvod.
2. Řídicí strategie.
- 3. Rozpoznávání.**
4. Analýza histogramu.
5. Metody díl po dílu.
6. Metody křížení dílů.
7. RANSAC.

Rozpoznávání – definice

► Pattern matching:

- obecně: hledání přítomnosti množiny znaků vzoru v neznámém signálu
- v počítačovém vidění: lokalizace modelu v cílovém obraze s požadavkem přesné shody
- např. hledání shody textu (search&replace)

► Pattern recognition:

- obecně: úloha nalezení kategorie (třídy) vzoru v neznámém signálu
- v počítačovém vidění: lokalizace segmentu v cílovém obraze, jehož třída odpovídá třídě modelu
- např. detekce RZ vozidla bez ohledu na státní příslušnost

Rozpoznávání – metody

- ▶ Rozdílové metody:
 - suma čtverců odchylek (vzoru/šablony a vyšetřovaného signálu)
 - suma čtverců odchylek s korekcí intenzity

- ▶ Korelační metody:
 - prostá korelace / normalizovaná korelace / modifikovaná normalizovaná korelace

- ▶ Analýza histogramu:
 - prostý rozdíl / metody díl po dílu / metody křížení dílů

- ▶ Statistické metody:
 - shluková analýza
 - RANSAC
 - Support Vector Machines

- ▶ Syntaktické rozpoznávání
- ▶ Neuronové sítě
- ▶ Fuzzy rozpoznávací systémy

Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

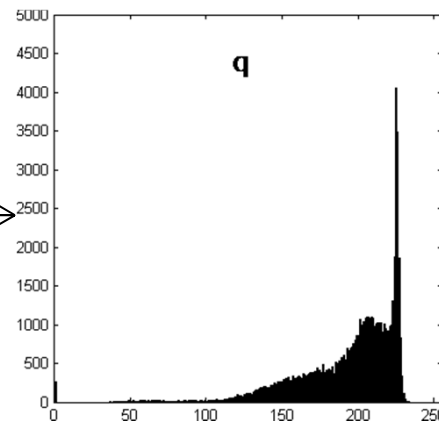


1. Úvod.
2. Řídicí strategie.
3. Rozpoznávání.
- 4. Analýza histogramu.**
5. Metody díl po dílu.
6. Metody křížení dílů.
7. RANSAC.

Analýza histogramu – definice

► Porovnávání dvou histogramů:

- databázový histogram $p(i)$ = histogram vzoru (model)
- aktuální histogram $q(i)$ = histogram objektu (neznámý signál)

► Porovnávání = určení vzdálenosti (podobnosti) histogramů:



$$d(p,q) = ?$$

Analýza histogramu – členění metod

► Třídy metod pro měření vzdálenosti dvou histogramů:

– prostý rozdíl

– metody díl po dílu (bin-by-bin)

→ vzdálenost Minkowského

→ vzdálenost Bhattacharyya

→ průnik histogramů

→ statistika χ^2

→ divergence Kullback-Leibler

→ divergence Jeffrey

– metody křížení dílů (cross-bin)

→ kvadratická vzdálenost

→ kumulativní vzdálenost

→ statistika Kolmogorov-Smirnov

Analýza histogramu – členění metod

► Třídy metod pro měření vzdálenosti dvou histogramů:

– prostý rozdíl

– metody díl po dílu (bin-by-bin)

→ vzdálenost Minkowského

→ vzdálenost Bhattacharyya

→ průnik histogramů

→ statistika χ^2

→ divergence Kullback-Leibler

→ divergence Jeffrey

– metody křížení dílů (cross-bin)

→ kvadratická vzdálenost

→ kumulativní vzdálenost

→ statistika Kolmogorov-Smirnov


Analýza histogramu – prostý rozdíl

► Prostý rozdíl:

- metrika porovnání celkových velikostí histogramů
- výhoda: velmi jednoduchá metoda
- nevýhoda: nezohledňuje rozložení dílů histogramů, ale pouze jejich celkovou energii tzn. nemá praktické použití pro lokalizaci šablony (jinak: udává jen prostý rozdíl počtu pixelů obrazů)

$$d_p = \left| \sum_i p(i) - \sum_i q(i) \right|$$

► Nemá význam u porovnávání šablon stejných rozměrů bez ohledu na hodnoty a rozložení pixelů:




$$\dim(P) = (256, 256) \rightarrow \sum_{i=0}^{255} p(i) = \dim(P,1) \cdot \dim(P,2) = 2^{16}$$

↓

$$d_p = 0 \Leftrightarrow |2^{16} - 2^{16}|$$

↑



$$\dim(Q) = (256, 256) \rightarrow \sum_{i=0}^{255} q(i) = \dim(Q,1) \cdot \dim(Q,2) = 2^{16}$$

Analýza histogramu – prostý rozdíl

► Příklad:

- detekce modelu oka porovnáváním histogramů šablony Q a obrazového segmentu P
- šablona = obraz oka ($q_1 \times q_2$ bodů)


► Algoritmus : pro každou přípustnou polohu (x,y) šablony ve vstupním obrazu proved'

- definuj obrazový segment $(x,y,x+q_1,y+q_2)$
- vypočítej vzdálenost $d(p,q)$ histogramu Q a histogramu P podle určené metriky
- hodnotu $d(p,q)$ zapiš do pole vzdáleností D na pozici (x,y)
- polohu šablony Q v obrazu P lokalizuj detekcí minima v poli vzdáleností D


P(512x512)



Q(30x20)



D(492x482)



Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

1. Úvod.
2. Řídicí strategie.
3. Rozpoznávání.
4. Analýza histogramu.
- 5. Metody díl po dílu.**
6. Metody křížení dílů.
7. RANSAC.

Analýza histogramu – členění metod

► Třídy metod pro měření vzdálenosti dvou histogramů:

– prostý rozdíl

– metody díl po dílu (bin-by-bin)

→ vzdálenost Minkowského

→ vzdálenost Bhattacharyya

→ průnik histogramů

→ statistika χ^2

→ divergence Kullback-Leibler

→ divergence Jeffrey

– metody křížení dílů (cross-bin)


→ kvadratická vzdálenost

→ kumulativní vzdálenost


→ statistika Kolmogorov-Smirnov

Analýza histogramu – metody díl po dílu

- Metody díl po dílu porovnávají pouze části histogramů se shodnými indexy:



- Výhoda metod: zohledňují rozdělení energie histogramů
- Nevýhoda metod: poziční metrika \Rightarrow geometricky podobné histogramy vykazují velkou vzdálenost



$$d(p, q) > d(r, s)$$

- Topografická vzdálenost se neuplatňuje:
 - hodnoty odpovídajících si indexů jsou porovnávány přímo (váha = 1)
 - hodnoty rozdílných indexů nejsou porovnávány vůbec (váha = 0)

Analýza histogramu – Minkowského vzdálenost


- ▶ Minkowského vzdálenost:
 - definována pomocí L^p normy
 - nejčastěji využívány normy L^1 , L^2 a L^∞

- ▶ Norma L^p (obecně metrika vzdálenosti v prostoru \mathfrak{R}^n , zde v \mathfrak{R}^2):

$$d^{L^p}(p, q) = \left(\sum_i |p(i) - q(i)|^p \right)^{1/p}$$


- ▶ Norma L^1 (Manhattan):

$$d^{L^1}(p, q) = \sum_i |p(i) - q(i)|$$




- ▶ Norma L^2 (Euclidean):

$$d^{L^2}(p, q) = \left(\sum_i (p(i) - q(i))^2 \right)^{1/2}$$



- ▶ Norma L^∞ (Chessboard):

$$d^{L^\infty}(p, q) = \left(\sum_i |p(i) - q(i)|^\infty \right)^{1/\infty} = \max\{|p(1) - q(1)|, |p(2) - q(2)|, \dots, |p(n) - q(n)|\}$$



Analýza histogramu – Minkowského vzdálenost

► Minkowského vzdálenost histogramu šablony () a histogramu segmentu – norma L^1 :

► $P(512,512)$



► $D(492 \times 482)$



► $\min(D)$




Analýza histogramu – Minkowského vzdálenost

► Minkowského vzdálenost histogramu šablony () a histogramu segmentu – norma L^2 :

► $P(512,512)$




► $D(492 \times 482)$



► $\min(D)$




Analýza histogramu – Minkowského vzdálenost

► Minkowského vzdálenost histogramu šablony () a histogramu segmentu – norma L^∞ :

► $P(512,512)$



► $D(492 \times 482)$



► $\min(D)$



Analýza histogramu – Bhattacharyya vzdálenost

► Koeficient Bhattacharyya:

– spojité rozložení:

$$\rho(p, q) = \int_{i \in I} \sqrt{p(i) \cdot q(i)} di \quad 0 \leq \rho(p, q) \leq 1 \quad I \subseteq \mathfrak{R}$$

– diskrétní rozložení:

$$\rho(p, q) = \sum_{i \in I} \sqrt{p(i) \cdot q(i)} \quad 0 \leq \rho(p, q) \leq 1 \quad I \subseteq \mathbb{Z}$$

► Vzdálenost Bhattacharyya:

$$d_B(p, q) = -\ln(\rho(p, q)) \quad 0 \leq d_B(p, q) \leq \infty$$

$$d_B(p, q) = \sqrt{1 - \rho(p, q)} \quad 0 < d_B(p, q) \leq 1$$


► Matematická interpretace:

– skalární součin vektorů p a q , jejichž prvky jsou odmocniny pravděpodobností $p(i)$ a $q(i)$ definovaných na totožné doméně X

► Geometrická interpretace:

– kosinus úhlu sevřeného vektory $p(i)$ a $q(i)$

Analýza histogramu – Bhattacharyya vzdálenost

► Bhattacharyya vzdálenost histogramu šablony () a histogramu segmentu:

► $P(512,512)$



► $D(492 \times 482)$



► $\min(D)$



Analýza histogramu – průnik histogramů

► Průnik histogramů:


– při shodných velikostech je ekvivalentní Minkowského vzdálenosti L_1

$$d_p(p, q) = 1 - \frac{\sum_i \min(p(i), q(i))}{S}$$

► kde S :

$$S = \sum_i p(i) = \sum_i q(i)$$


Analýza histogramu – průnik histogramů

► Průnik histogramu šablony () a histogramu segmentu:

► $P(512,512)$



► $D(492 \times 482)$



► $\min(D)$



Analýza histogramu – statistika χ^2

► Statistika χ^2 :


- udává pravděpodobnost, že první histogram náleží do třídy druhého histogramu
- pro nízký počet pozorování (hodnoty v histogramu) velmi nepřesné
- žádný díl histogramu nesmí být nulový

$$\chi^2(p, q) = \sum_i \frac{(p(i) - \mu(i))^2}{\mu(i)}$$

► kde $\mu(i)$ značí průměrnou hodnotu totožných dílů obou histogramů:

$$\mu(i) = \frac{p(i) + q(i)}{2}$$


Analýza histogramu – statistika χ^2

► Statistika χ^2 histogramu šablony () a histogramu segmentu:


► P(512,512)



► D(492x482)



► min(D)




Analýza histogramu – divergence Kullback-Leibler

► Divergence Kullback-Leibler:

- udává míru shody dvou rozložení
- nevýhoda: asymetrická metoda, velmi citlivá na rozdělení dílů histogramů

$$d_{KL}(p, q) = \sum_i p(i) \cdot \ln \frac{p(i)}{q(i)} \quad d_{KL}(p, q) \geq 0$$


Analýza histogramu – divergence Kullback-Leibler

► Divergence Kullback-Leibler histogramu šablony () a histogramu segmentu:

► $P(512,512)$



► $D(492 \times 482)$



► $\min(D)$



Analýza histogramu – divergence Jeffrey

► Divergence Jeffrey:

- udává míru shody dvou rozložení
- symetrická verze divergence Kullback-Leibler (respektuje rozložení p i q histogramu)
- robustní metrika vzhledem ke změnám rozdělení dílů histogramu

$$d_J(p, q) = \sum_i \left(p(i) \cdot \ln \frac{p(i)}{\mu(i)} + q(i) \cdot \ln \frac{q(i)}{\mu(i)} \right) \quad d_J(p, q) \geq 0$$

- kde $\mu(i)$ značí průměrnou hodnotu totožných dílů obou histogramů:

$$\mu(i) = \frac{p(i) + q(i)}{2}$$

Analýza histogramu – divergence Jeffrey

► Divergence Jeffrey histogramu šablony () a histogramu segmentu:

► P(512,512)



► D(492x482)



► min(D)



Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

1. Úvod.
2. Řídicí strategie.
3. Rozpoznávání.
4. Analýza histogramu.
5. Metody díl po dílu.
- 6. Metody křížení dílů.**
7. RANSAC.

Analýza histogramu – členění metod

► Třídy metod pro měření vzdálenosti dvou histogramů:

– prostý rozdíl

– metody díl po dílu (bin-by-bin)

→ vzdálenost Minkowského

→ vzdálenost Bhattacharyya

→ průnik histogramů

→ statistika χ^2

→ divergence Kullback-Leibler

→ divergence Jeffrey

– metody křížení dílů (cross-bin)


→ kvadratická vzdálenost

→ kumulativní vzdálenost

→ statistika Kolmogorov-Smirnov


Analýza histogramu – metody křížení dílů

- Metody křížení dílů porovnávají i části histogramů s různými indexy:



- Uplatňuje se topografická vzdálenost dílů histogramu:

- globálně mají metody křížení dílů lepší výsledky, než metody díl po dílu
- základní topografická vzdálenost = lineární jednotková metrika



Analýza histogramu – kvadratická vzdálenost

- ▀ Kvadratická vzdálenost je definována:

$$d_Q(p, q) = \sqrt{(p - q) \cdot S \cdot (p - q)^T}$$

- ▀ kde p resp. q jsou vektory histogramů obsahující prvky $p(i)$ a $q(i)$:

$$p = (p(1), p(2), \dots, p(n)), \quad q = (q(1), q(2), \dots, q(n))$$

- ▀ a S je čtvercová podobnostní matice:

$$S = (s_{ij}) = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1n} \\ s_{21} & s_{22} & \cdots & s_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & \cdots & s_{nn} \end{pmatrix}$$

- ▀ Prvky matice vyjadřují podobnost (vzdálenost) dílů histogramu:
 - s_{ij} = vzdálenost mezi dílem i histogramu p a dílem j histogramu q
 - pokud je S normalizovaná diagonální matice, pak:


$$d_Q(p, q) = d_{L_2}(p, q)$$

Analýza histogramu – kvadratická vzdálenost

► Základní tvary matice podobností S:

– topologická lineární vzdálenost:


$$s_{ij} = 1 - \frac{d_{ij}}{d_{\max}} \Rightarrow S_1 = \begin{pmatrix} 1 & 0.9961 & \dots & 0.0039 \\ 0.9961 & 1 & \dots & 0.0078 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0039 & 0.0078 & \dots & 1 \end{pmatrix}$$



pozn.: topografická vzdálenost $d_{ij} \rightarrow$ např. $\text{abs}(i-j)$


– topologická logaritmická vzdálenost:

$$s_{ij} = 1 - \ln \frac{d_{ij}}{d_{\max}} \Rightarrow S_2 = \begin{pmatrix} 1 & 0.9961 & \dots & 0.3088 \\ 0.9961 & 1 & \dots & 0.3108 \\ \vdots & \vdots & \ddots & \vdots \\ 0.3088 & 0.3108 & \dots & 1 \end{pmatrix}$$



– topologická identita:

$$s_{ij} = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases} \Rightarrow S_3 = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix}$$



Analýza histogramu – kvadratická vzdálenost

► Kvadratická vzdálenost histogramu šablony () a histogramu segmentu (S_1):

► $P(512,512)$				
► $D(492 \times 482)$				
► $\min(D)$				

Analýza histogramu – kvadratická vzdálenost

► Kvadratická vzdálenost histogramu šablony () a histogramu segmentu (S_2):

► $P(512,512)$				
► $D(492 \times 482)$				
► $\min(D)$				

Analýza histogramu – kumulativní vzdálenost


- Kumulativní vzdálenost je definována:

$$d_c(p, q) = \sum_i |p'(i) - q'(i)|$$

- kde p' resp. q' je kumulativní histogram p resp. q histogramu:

$$p'(i) = \sum_{j=1}^{j \leq i} p(j)$$

$$q'(i) = \sum_{j=1}^{j \leq i} q(j)$$



- Kumulativní vzdálenost = Minkowského vzdálenost L_1 normy kumulativních histogramů:

$$d_c(p, q) = d_{L_1}(p', q')$$

Analýza histogramu – kumulativní vzdálenost

► Kumulativní vzdálenost histogramu šablony () a histogramu segmentu:



Analýza histogramu – statistika Kolmogorov-Smirnov



Statistika Kolmogorov-Smirnov:

$$d_{KS}(p, q) = \max |p'(i) - q'(i)|$$


kde p' resp. q' je kumulativní histogram p resp. q histogramu:

$$p'(i) = \sum_{j=1}^{j \leq i} p(i)$$

$$q'(i) = \sum_{j=1}^{j \leq i} q(i)$$




Analýza histogramu – statistika Kolmogorov-Smirnov

► Statistika Kolmogorov-Smirnov histogramu šablony () a histogramu segmentu:

► $P(512,512)$



► $D(492 \times 482)$



► $\min(D)$



Porozumění obsahu obrazu

Karel Horák



Rozvrh přednášky:

1. Úvod.
2. Řídicí strategie.
3. Rozpoznávání.
4. Analýza histogramu.
5. Metody díl po dílu.
6. Metody křížení dílů.
- 7. RANSAC.**

RANSAC – definice

► RANSAC = RANdom SAmple Consensus:

- metoda vybírá náhodnou skupinu dat ze všech měření (odhad parametrů modelu)
- použití např. pro řešení korespondenčního problému
- základní myšlenka: každá naměřená data (tedy i obrazová) jsou složena ze správných hodnot a z chyb → úkolem je separovat tyto dvě třídy
- iterativní algoritmus

► Vlastnosti:

- výhoda: robustní určení parametrů modelu díky hypoteticky úplnému vyřazení chybných dat
- nevýhoda: neexistuje předem známá horní časová hranice doby trvání výpočtu (pokud je v implementaci pevně stanovena, výsledný model nemusí být nutně nejlepší ze všech možností)

RANSAC – zadání úlohy

- ▶ Terminologie úlohy řešené pomocí RANSAC:
 - k dispozici je celkem M vzorků měřených dat (např. výslednic korespondenčních párů)
 - parametry modelu jsou odhadovány z $N \subseteq M$ vzorků
 - p_q značí pravděpodobnost náhodného výběru takové skupiny dat, která právě náleží správnému modelu
 - p_{fail} značí pravděpodobnost ukončení výpočtu, aniž by byl nalezen dostačující model (za předpokladu existence alespoň jednoho vyhovujícího modelu)
- ▶ Formální vstupy metody:
 - data = sada pozorovaných vzorků
 - model = aktuálně vypočtený model
 - N = minimální počet vzorků potřebných pro určení modelu (určuje velikost výběrové množiny)
 - L = maximální počet povolených iterací
 - T = hodnota prahu určující shodu dat (výběru) s modelem
 - D = počet vzorků potřebných k přijmutí správnosti modelu
- ▶ Formální výstupy:
 - \mathbf{x} = vektor parametrů modelu, který nejlépe vyhovuje datům

RANSAC – algoritmus

► Postup výpočtu:

- náhodně vyber alespoň N vzorků z M
- z vybraných vzorků sestav model
- urči počet vzorků K ($<M$), které vyhovují vypočtenému modelu s parametry \mathbf{x} s tolerancí T
- pokud je $K>D$, přijmi aktuálně vypočtený model a výpočet ukonči
- opakuj výpočet od kroku jedna maximálně L -krát a poté ukonči výpočet s $\mathbf{x}=\mathbf{0}$

► Výpočet pravděpodobností:

- p_{fail} :

$$p_{fail} = (1 - (p_q)^N)^L$$

- maximální počet povolených opakování L :

$$L = \frac{\log(p_{fail})}{\log(1 - (p_q)^N)}$$

RANSAC – příklad

- ▶ Příklad – korespondenční problém:
 - dvojice stereo-snímků s vyznačenými významnými body
 - M je množina všech možných korespondencí typu každý s každým
 - metoda RANSAC odstraňuje ty korespondence, které nevyhovují většinovému modelu lineárního posunu

