

# Popis zobrazení pomocí fuzzy logiky

## diplomová práce

Ján Fröhlich

KM, FJFI, ČVUT

23. dubna 2009

## 1 Úvod

- Základy fuzzy logiky
- Popis zobrazení pomocí fuzzy logiky
- Fuzzy logika v širším smyslu
- Cíle práce
- Aproximace zobrazení

## 2 Výsledky

- Po částech lineární regrese
- Příklad: funkce jedné nezávislé proměnné
- Aproximace nelineárních zobrazení
- Konstrukce tvrzení Lukasiewiczovy logiky

## 3 Závěr

# Fuzzy logika

## Uvažování o *částečně pravdivých výrocích*

- rozšíření spojek, standardní algebra na  $[0, 1]$ ,
- modus ponens, axiomy, bezespornost, úplnost, . . . ,
- popis zobrazení:  $e_{\mathcal{A}}(\varphi) = f(e_{\mathcal{A}}(v_1), \dots, e_{\mathcal{A}}(v_k))$

# Konjunkce t-normy

binární operace t-norma  $\mathbf{t} : [0, 1]^2 \rightarrow [0, 1]$ :

1 komutativita

$$\mathbf{x} \mathbf{t} \mathbf{y} = \mathbf{y} \mathbf{t} \mathbf{x},$$

2 asociativita

$$\mathbf{x} \mathbf{t} (\mathbf{y} \mathbf{t} \mathbf{z}) = (\mathbf{x} \mathbf{t} \mathbf{y}) \mathbf{t} \mathbf{z},$$

3 monotonie

$$\mathbf{x} \leq \mathbf{y} \text{ implikuje } \mathbf{x} \mathbf{t} \mathbf{z} \leq \mathbf{y} \mathbf{t} \mathbf{z},$$

4 omezení shora

$$\mathbf{1} \mathbf{t} \mathbf{x} = \mathbf{x}.$$

# Implikace a reziduum t-normy

- pravidlo *modus ponens*  $(\varphi \& (\varphi \rightarrow \psi)) \rightarrow \psi$
- požaduje se:
  - $x \Rightarrow_{\mathbf{t}} y = 1$  právě tehdy, když  $x \leq y$ ,
  - pravidlo modus ponens je tautologie
- pravdivost závěru  $\psi$  je zdola omezena pravdivostí předpokladu, tj. stupněm *současné* pravdivosti výroků  $\varphi$  a  $\varphi \rightarrow \psi$ ,
- při interpretaci *konjunkce* v předpokladu t-normou  $\mathbf{t}$ :

$$(x \mathbf{t} (x \Rightarrow_{\mathbf{t}} y)) \leq y,$$

- reziduum  $\Rightarrow_{\mathbf{t}}$  t-normy  $\mathbf{t}$  je funkce  $\Rightarrow_{\mathbf{t}}: [0, 1]^2 \rightarrow [0, 1]$ :

$$x \Rightarrow_{\mathbf{t}} y = \sup\{z \mid x \mathbf{t} z \leq y\}.$$

# Lukasiewiczova logika

## Interpretace spojek

- $x \otimes y := 0 \vee (x + y - 1)$ ,
- $x \Rightarrow_{\otimes} y := 1 \wedge (1 - x + y)$ ,

## Reprezentace funkcí

- $(0,8 \oplus 0,7) \ominus 0,6 = \underline{1} \ominus 0,6 = 0,4 \neq \underline{1,5} - 0,6 = 0,9$ ,
- $0,8 \oplus (0,7 \ominus 0,6) = 0,8 \oplus 0,1 = 0,9 = 0,8 + 0,1 = 0,9$ ,
- po částech lineární funkce s celočíselnými koeficienty,
- reprezentace funkce  $f: \Phi = \bigvee_{i \in \hat{p}} \left( \Phi_{h_i} \& \bigwedge_{j \in \hat{q}_i} \neg \Psi_{g_{i,j}}^{\oplus m_{i,j}} \right)$

# Lukasiewiczova logika

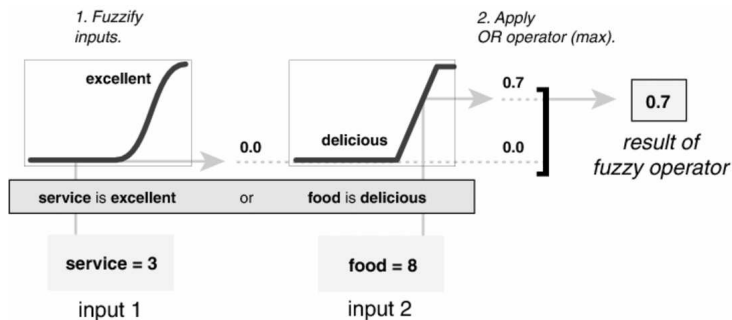
## Interpretace spojek

- $x \otimes y := 0 \vee (x + y - 1)$ ,
- $x \Rightarrow_{\otimes} y := 1 \wedge (1 - x + y)$ ,

## Reprezentace funkcí

- $(0,8 \oplus 0,7) \ominus 0,6 = \underline{1} \ominus 0,6 = 0,4 \neq \underline{1,5} - 0,6 = 0,9$ ,
- $0,8 \oplus (0,7 \ominus 0,6) = 0,8 \oplus 0,1 = 0,9 = 0,8 + 0,1 = 0,9$ ,
- po částech lineární funkce s celočíselnými koeficienty,
- reprezentace funkce  $f: \Phi = \bigvee_{i \in \hat{p}} \left( \Phi_{h_i} \& \bigwedge_{j \in \hat{q}_i} \neg \Psi_{g_{i,j}}^{\oplus m_{i,j}} \right)$


# Fuzzifikace vstupů



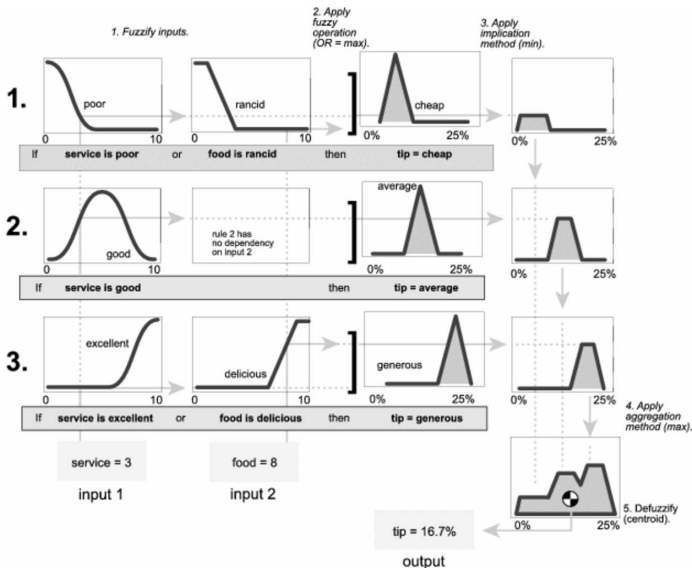
<http://www.mathworks.com/products/fuzzylogic/>



# Fuzzy usuzování




# Fuzzy odvozování a defuzifikace




# Úkoly

- 1 Implementovat algoritmus pro převod zobrazení na tvrzení
- 2 Aproximace dat a popis zobrazení fuzzy logice:
  - srozumitelnost tvrzení vs. přesnost reprezentace,
  - výroková vs. predikátová fuzzy logika,
  - efektivita pro velké soubor dat a vyšší dimenze
- 3 Navrhnout a implementovat algoritmy v MATLABu

## Cíl: zadané body



## Cíl: výsledná aproximace



# Volba vhodného způsobu aproximace

## Otázka srozumitelnosti

- přímá úměrnost,
- lineární kombinace,
- nelineární závislost: součin dvou proměnných,
- oblast linearity — konvexní mnohostěn

## Některé známé metody aproximace

- umělé neuronové sítě (ANN),
- metoda opěrných bodů (SVM),
- genetické algoritmy

# Volba vhodného způsobu aproximace

## Otázka srozumitelnosti

- přímá úměrnost,
- lineární kombinace,
- nelineární závislost: součin dvou proměnných,
- oblast linearity — konvexní mnohostěn

## Některé známé metody aproximace

- umělé neuronové sítě (ANN),
- metoda opěrných bodů (SVM),
- genetické algoritmy

# Evoluční algoritmy a po částech lineární regrese

- prohledávání prostoru řešení
- jedinec, populace, *ohodnocovací funkce*, *selekce*, *mutace*, *křížení*, *reprodukce*
- predikátová nebo výroková logika
- hledat přímo tvrzení nebo funkci
- vstup: aproximace nebo soubor dat
- kritéria optimalizace, konvergence populace
- efektivita



# Navržený postup

Hledá se  $f : [0, 1]^k \rightarrow [0, 1]$ . Zadáno  $n$  bodů:  $\mathbf{x}_i \in [0, 1]^k$ ,  $y_i \in [0, 1]$ ,  $i \in \{1, \dots, n\}$ .

- 1 Sestaví se *kd*-trie.
- 2 Proveďte se lineární regrese bodů v buňkách.
- 3 Rozliší se *nosné* a *hraniční* buňky.

úspěšnost proložení

koeficient určení:  $R^2 = \frac{\text{součet čtverců modelových hodnot}}{\text{celkový součet čtverců}} \in [0, 1]$

- 4 Sloučí se buňky se stejnou závislostí (testování lineárních hypotéz).


největší možné konvexní oblasti

míra konvexnosti:  $\gamma = \frac{\text{součet objemů sloučených buněk}}{\text{objem konvexního obalu vrcholů buňky}} \in (0, 1]$

# Navržený postup

Hledá se  $f : [0, 1]^k \rightarrow [0, 1]$ . Zadáno  $n$  bodů:  $\mathbf{x}_i \in [0, 1]^k$ ,  $y_i \in [0, 1]$ ,  $i \in \{1, \dots, n\}$ .

**1** Sestaví se *kd*-trie. Příklad — dvě nezávislé proměnné:



# Navržený postup

Hledá se  $f : [0, 1]^k \rightarrow [0, 1]$ . Zadáno  $n$  bodů:  $\mathbf{x}_i \in [0, 1]^k$ ,  $y_i \in [0, 1]$ ,  $i \in \{1, \dots, n\}$ .

- 1 Sestaví se *kd*-trie.
- 2 Proveďte se lineární regrese bodů v buňkách.
- 3 Rozliší se *nosné* a *hraniční* buňky.

úspěšnost proložení

koeficient určení:  $R^2 = \frac{\text{součet čtverců modelových hodnot}}{\text{celkový součet čtverců}} \in [0, 1]$

- 4 Sloučí se buňky se stejnou závislostí (testování lineárních hypotéz).

největší možné konvexní oblasti

míra konvexnosti:  $\gamma = \frac{\text{součet objemů sloučených buněk}}{\text{objem konvexního obalu vrcholů buňky}} \in (0, 1]$

# Navržený postup

Hledá se  $f : [0, 1]^k \rightarrow [0, 1]$ . Zadáno  $n$  bodů:  $\mathbf{x}_i \in [0, 1]^k$ ,  $y_i \in [0, 1]$ ,  $i \in \{1, \dots, n\}$ .

- 1 Sestaví se *kd*-trie.
- 2 Proveďte se lineární regrese bodů v buňkách.
- 3 Rozliší se *nosné* a *hraniční* buňky.

úspěšnost proložení

koeficient určení:  $R^2 = \frac{\text{součet čtverců modelových hodnot}}{\text{celkový součet čtverců}} \in [0, 1]$

- 4 Sloučí se buňky se stejnou závislostí (testování lineárních hypotéz).

největší možné konvexní oblasti

míra konvexnosti:  $\gamma = \frac{\text{součet objemů sloučených buněk}}{\text{objem konvexního obalu vrcholů buňky}} \in (0, 1]$

# Navržený postup

Hledá se  $f : [0, 1]^k \rightarrow [0, 1]$ . Zadáno  $n$  bodů:  $\mathbf{x}_i \in [0, 1]^k$ ,  $y_i \in [0, 1]$ ,  $i \in \{1, \dots, n\}$ .

- 1 Sestaví se *kd*-trie.
- 2 Proveďte se lineární regrese bodů v buňkách.
- 3 Rozliší se *nosné* a *hraniční* buňky.

úspěšnost proložení


koeficient určení:  $R^2 = \frac{\text{součet čtverců modelových hodnot}}{\text{celkový součet čtverců}} \in [0, 1]$

- 4 Sloučí se buňky se stejnou závislostí (testování lineárních hypotéz).

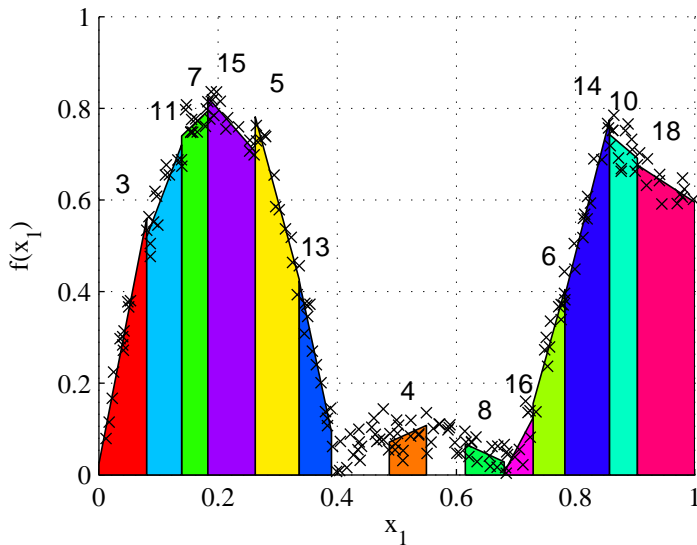
největší možné konvexní oblasti

míra konvexnosti:  $\gamma = \frac{\text{součet objemů sloučených buněk}}{\text{objem konvexního obalu vrcholů buňky}} \in (0, 1]$


# Zadané body



# kd-trie, lineární regrese




# Sloučení buněk se stejnou závislostí





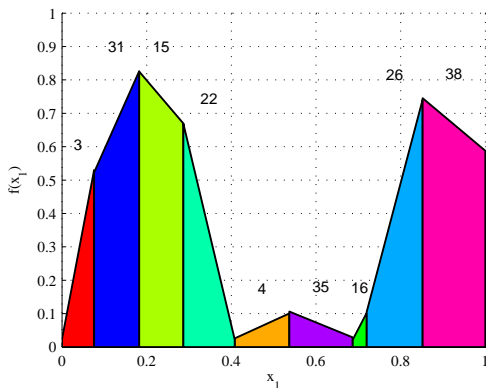
# Nalezení oblastí linearity (klasifikace)

- 1 Lineární klasifikací se určí nadroviny oddělující sousední buňky.
- 2 Pomocí nalezených nadrovin se sestrojí konvexní mnohostrany.




# Nalezení oblastí linearity (průsečíky)

- 1 Určí se průsečíky nadrovin sousedních buněk.
- 2 Průsečíky se promítnou do prostoru nezávislých proměnných.



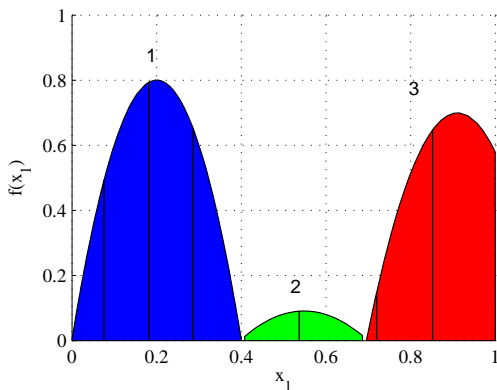
# Hledání oblastí extrémů

- 1 Naleznou se lokální maxima.
- 2 V každé oblasti maxima se provede kvadratická regrese.




# Hledání oblastí extrémů

- 1 Naleznou se lokální maxima.
- 2 V každé oblasti maxima se provede kvadratická regrese.



## Příklad: po částech lineární funkce ...



## ... reprezentace funkce v Lukasiewiczově logice

$$\left( \left( \frac{1}{2} \oplus \frac{1}{10} \ominus \frac{1}{2} \right) \& \left( \neg \left( \frac{1}{2} \ominus \frac{1}{10} \oplus \varphi \ominus \frac{1}{2} \right)^{\oplus 2} \wedge \neg \left( \frac{1}{2} \ominus \varphi \ominus \frac{1}{2} \right)^{\oplus 4} \right) \right)$$

∨

$$\left( \left( \frac{1}{2} \oplus \frac{3}{10} \ominus \varphi^{\oplus 2} \ominus \frac{1}{2} \right) \& \left( \neg \left( \frac{1}{2} \ominus \frac{1}{10} \oplus \varphi \ominus \frac{1}{2} \right) \wedge \neg \left( \frac{1}{2} \oplus \frac{1}{10} \ominus \varphi \ominus \frac{1}{2} \right)^{\oplus 8} \right) \right)$$

∨

$$\left( \left( \frac{1}{2} \oplus \varphi^{\oplus 4} \ominus \frac{1}{2} \right) \& \left( \neg \left( \frac{1}{2} \oplus \varphi \ominus \frac{1}{2} \right)^{\oplus 16} \wedge \neg \left( \frac{1}{2} \ominus \varphi \ominus \frac{1}{2} \right) \right) \right)$$

# Závěr

Vlastnosti navržených algoritmů:

- jednoduché nastavení úrovně aproximace,
- oblasti linearity — konvexní mnohostěny,
- umožní nalézt spojitou po částech lineární aproximaci,
- snadné nalezení lokálních extrémů,
- regrese v oblastech extrémů usnadní konstrukci predikátů,
- využívá lineární metody.

# Děkuji za pozornost.