

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

TEORIE INFORMACE STRUČNÝ ÚVOD PRO KURZ MSTU

Autor textu:
Ing. Petr Honzík, Ph.D.

Květen 2014

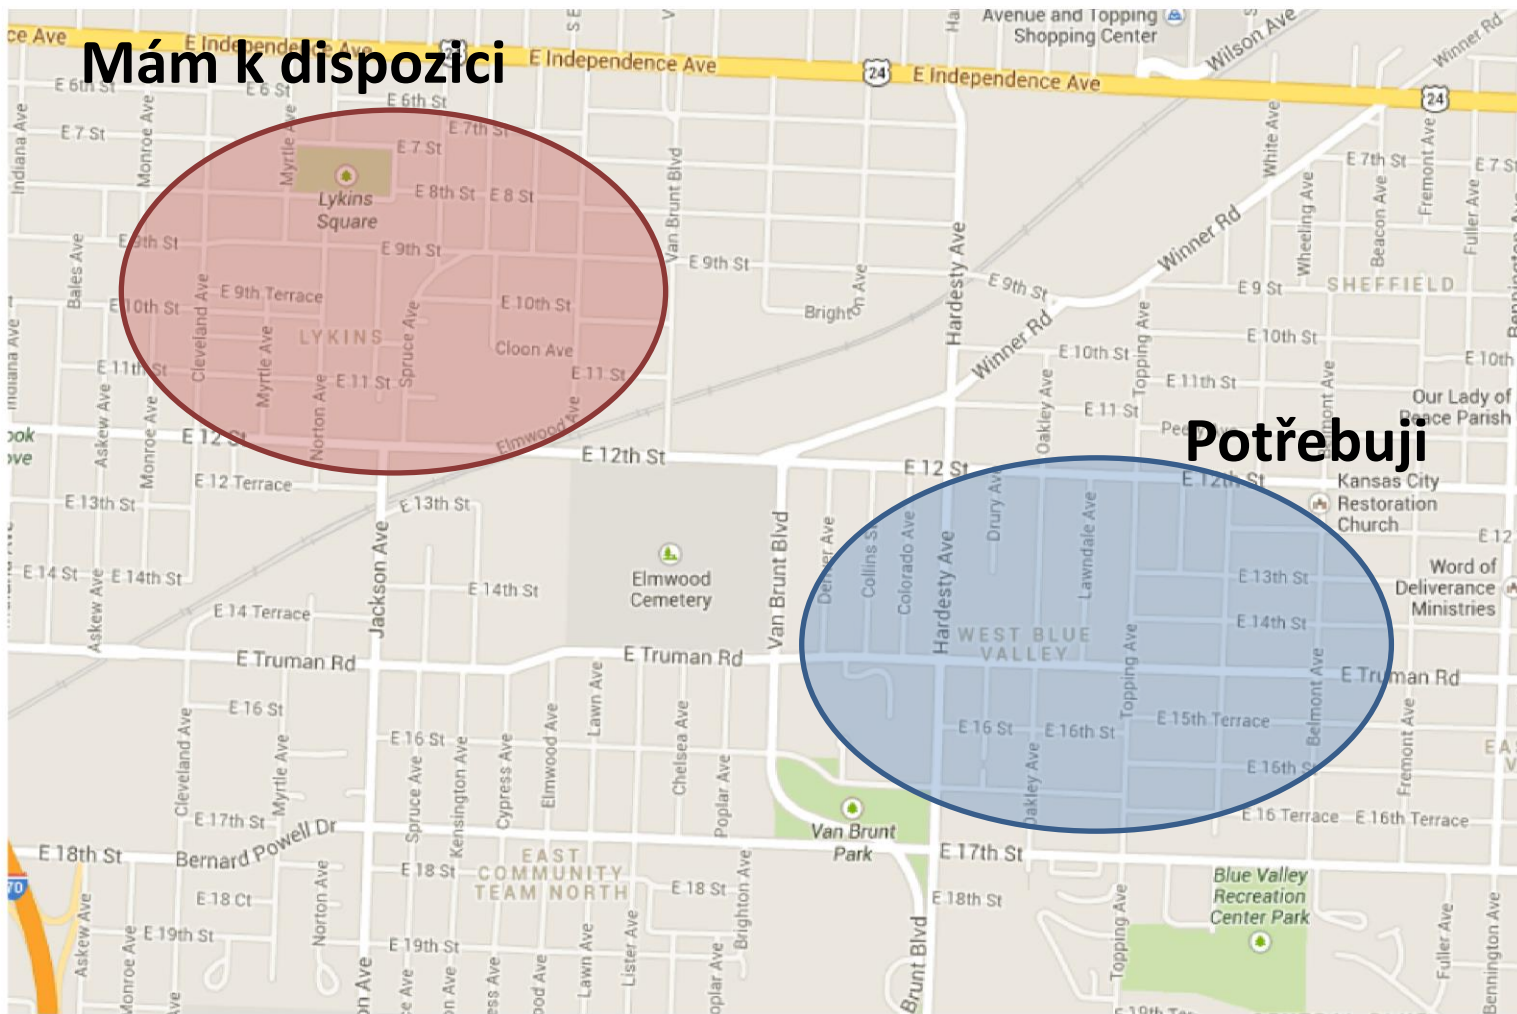
Komplexní inovace studijních programů a zvyšování kvality výuky na FEKT VUT v Brně
OP VK CZ.1.07/2.2.00/28.0193



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

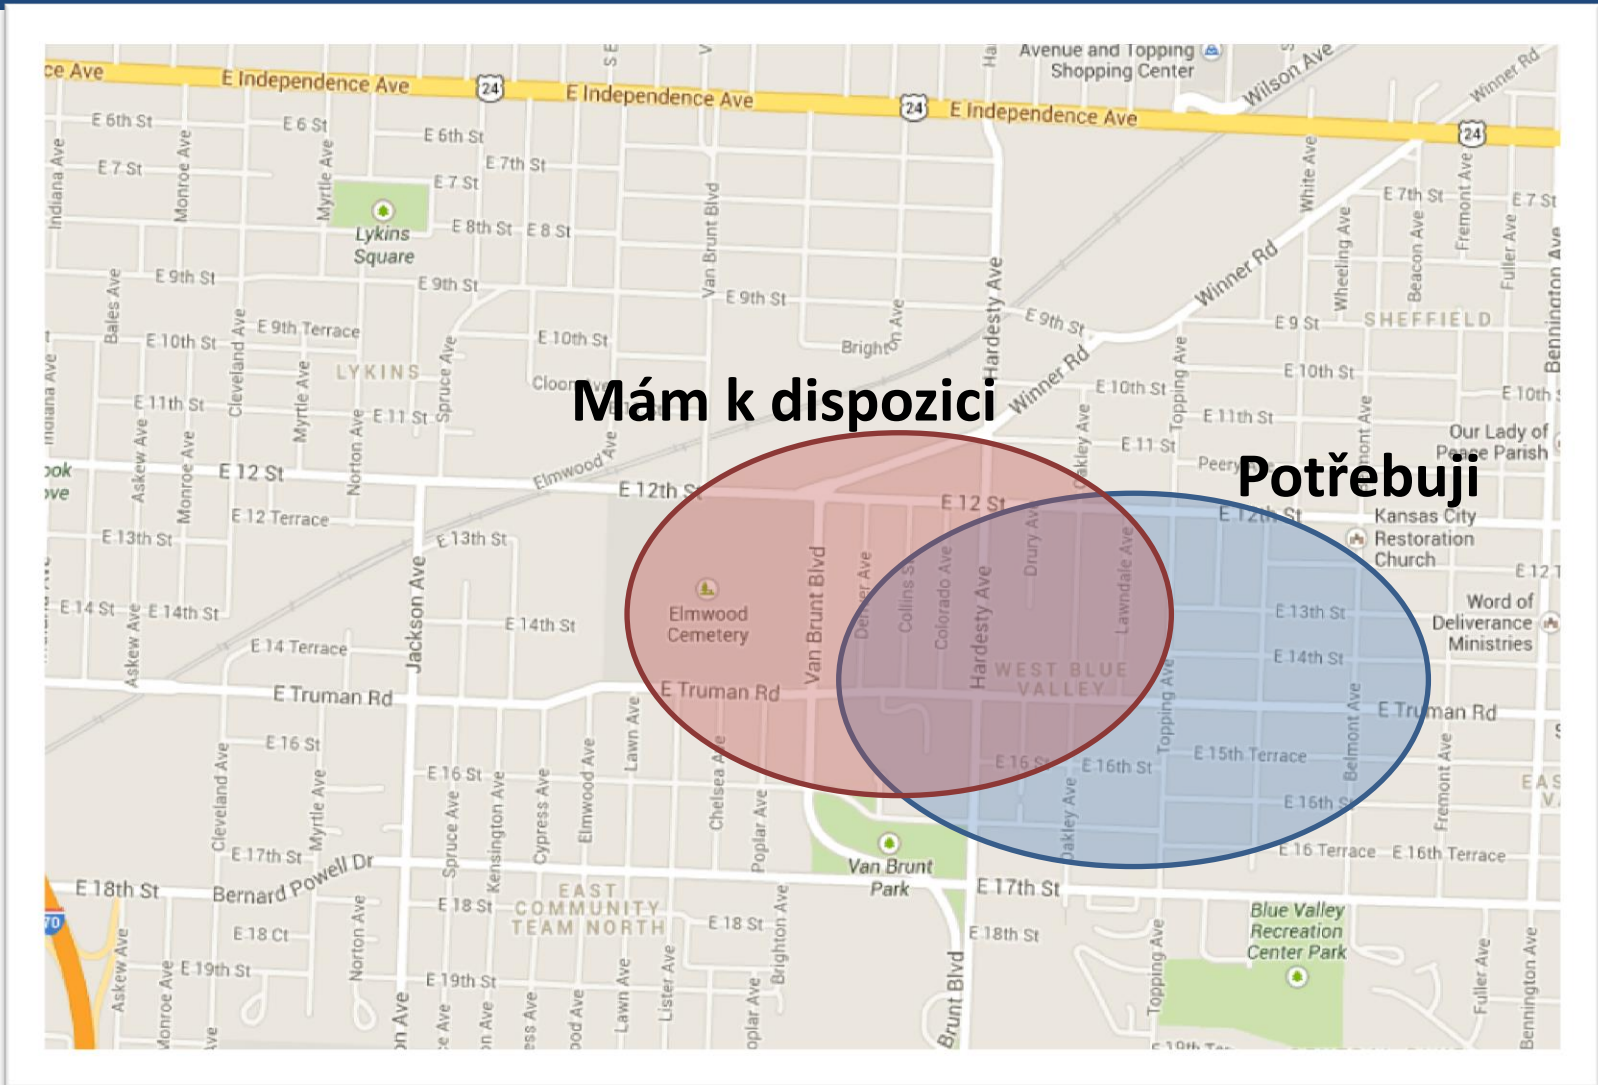
TI – intuitivně

Mám k dispozici




Potřebuji

TI – intuitivně




TI – základní pojmy



- $H(X)$ – entropie (*entropy, marginal entropy*)
- $H(X,Y)$ – sdružená entropie (*joint entropy*)
- $H(X|Y)$ – podmíněná entropie (*conditional entropy*)
- $I(X,Y)$ – vzájemná informace (*mutual information*)

TI – základní pojmy



Odvoďte:

$$I(X,Y) = H(X,Y) \dots ?$$

$$H(Y|X) = H(Y) \dots ?$$

$$H(X)+H(Y) = H(X,Y) \dots ?$$

$$I(X,X) = \dots ?$$

Možná řešení (může jich být více)

$$I(X,Y) = H(X,Y) - H(X|Y) - H(Y|X)$$

$$H(Y|X) = H(Y) - I(X,Y)$$

$$H(X)+H(Y) = H(X,Y) + I(X,Y)$$

$$I(X,X) = H(X) \text{ (self-information)}$$

Kvantifikace informace

- Je dána množina hodnot \mathcal{X} . Množství informace získané zjištěním konkrétní hodnoty z množiny \mathcal{X} je definováno jako **záporný logaritmus pravděpodobnosti výběru** této hodnoty.

$$I(x) = -\log p(x)$$

- Automaticky je předpokládáno, že jednotlivé výběry jsou náhodné nezávislé jevy.
- Logaritmus bude nadále počítán se základem 2, jednotkou je [bit] (základ 2 však není podmínkou).

Kvantifikace informace – příklady

- Je-li tedy $\mathcal{X} = \{a, b, c\}$, množství informace získané zjištěním hodnoty a :

$$I(a) = -\log p(a) = -\log \frac{1}{3} = 1,58$$

$$I(a) = I(b) = I(c)$$

- Je-li šest různých měření hodnoty z množiny \mathcal{X} definováno vektorem $\mathbf{x} = [a, b, b, a, c, a]$

$$I(a) = -\log p(a) = -\log \frac{3}{6} = 1$$

$$I(b) = -\log p(b) = -\log \frac{2}{6} = 1,58$$

$$I(c) = -\log p(c) = -\log \frac{1}{6} = 2,58$$

Entropie

- **střední hodnota informace** $I(X)$ získaná zjištěním konkrétní hodnoty X

$$H(X) = E[I(X)] = - \sum_{\forall x \in \mathcal{X}} p(x) I(x) = - \sum_{\forall x \in \mathcal{X}} p(x) \log p(x)$$

- Je-li $\mathbf{x} = [a, b, b, a, c, a]$, pak

$$H(\mathbf{x}) = E[I(\mathbf{x})] = - \sum_{\forall x \in \mathcal{X}} p(x) \log p(x) = \\ - \frac{3}{6} \log \frac{3}{6} - \frac{2}{6} \log \frac{2}{6} - \frac{1}{6} \log \frac{1}{6} = \frac{3}{6} 1 + \frac{2}{6} 1,58 + \frac{1}{6} 2,58 = 1,46$$

Entropie ze sdružené pravděpodobnosti

- $p(x)$ je tzv. **marginální pravděpodobnost** ve sdružené pravděpodobnosti a je definována:

$$p(x) = \sum_{\forall y \in Y} p(x, y)$$

- entropii veličiny X pak lze zapsat jako:

$$H(X) = - \sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log p(x)$$

Sdružená a podmíněná entropie

- sdružená entropie je definována přímo z matice sdružené pravděpodobnosti:

$$H(X, Y) = - \sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log p(x, y)$$

- podmíněná pravděpodobnost je definována jako:

$$p(x|y) = \frac{p(x, y)}{p(y)}$$

- z čehož lze dosazením získat podmíněnou entropii:

$$H(X|Y) = - \sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log p(x|y) = - \sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log \frac{p(x, y)}{p(y)}$$

Vzájemná informace

- vzájemná informace

$$I(X, Y) = H(X) - H(X|Y) = H(Y) - H(Y|X)$$

- je odvozena z kombinací předešlého jako:

$$- \sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log p(x) + \sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log \frac{p(x, y)}{p(y)} =$$

$$\sum_{\forall x \in X} \sum_{\forall y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)}$$

- Poznámka: jsou-li veličiny X a Y nezávislé, potom platí, že $p(x, y) = p(x)p(y)$. Podíl těchto pravděpodobností je roven 1 a $\log 1 = 0$. Tedy pro dvě nezávislé veličiny bude vzájemná informace rovna 0.

Informační zisk (IG)

- **informační zisk** (information gain) je synonymum pro
 - vzájemnou informaci (tak bude chápáno v kurzu MSTU; použití v rozhodovacích stromech, výběru příznaků)
 - Kullback-Leiblerovu divergenci, množství chybějící informace, je-li použito optimální kódování dle rozložení q , avšak skutečné je p

$$D_{KL}(p, q) = \sum_{\forall y \in Y} p \log \frac{p}{q}$$

shodnost s *IG* však platí pouze pokud D_{KL} je definováno jako funkce veličin X a Y ; je-li D_{KL} definováno jako funkce rozložení p a q , tak pro něj neplatí axiom symetrie

- existuje více způsobů normalizace IG (*information gain ratio*, *symmetric uncertainty*, *normalized information gain*)