

KMI/ZZD – Získávání znalostí z dat

Shlukování

Jan Konečný

6. března 2012

Měření podobnosti a vzdálenosti

Výsledek shlukování ve velké míře závisí na měření podobnosti a vzdálenosti.

Vybrané funkce vzdálenosti

1. Euklidovská vzdálenost

$$d(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

2. Hammingova vzdálenost

$$d(\vec{x}, \vec{y}) = \sum_{i=1}^n |x_i - y_i|$$

3. Tchebyschevova vzdálenost

$$d(\vec{x}, \vec{y}) = \max_{i=1}^n |x_i - y_i|$$

4. Minkowského vzdálenost

$$d(\vec{x}, \vec{y}) = \sqrt[p]{\sum_{i=1}^n |x_i - y_i|^p}, \quad p > 0$$

5. Canberrova vzdálenost

$$d(\vec{x}, \vec{y}) = \sum_{i=1}^n \frac{|x_i - y_i|}{x_i + y_i}, \quad x_i \text{ a } y_i \text{ jsou kladné}$$

6. Úhlová separace

$$d(\vec{x}, \vec{y}) = \frac{\sum_{i=1}^n x_i y_i}{\left[\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i^2 \right]^{\frac{1}{2}}}$$

Vzdálenost a podobnost binárních dat

Uvažujme dva binární vektory

$$\vec{x} = [x_1, x_2, \dots, x_n]^T \quad \text{a} \quad \vec{y} = [y_1, y_2, \dots, y_n]^T.$$

Porovnáme je po složkách, počítáme specifické kombinace 0 a 1

a : $x_k = 1$ a $y_k = 1$

b : $x_k = 0$ a $y_k = 1$

c : $x_k = 1$ a $y_k = 0$

d : $x_k = 0$ a $y_k = 0$

	1	0
1	<i>a</i>	<i>b</i>
0	<i>c</i>	<i>d</i>

Následně se zjistí podobnost (viz následující slajdu)

- ▶ koeficient shody $\frac{a+b}{a+b+c+d}$
- ▶ Russell & Rao $\frac{a}{a+b+c+d}$
- ▶ Jacard index $\frac{a}{a+b+c}$
- ▶ Czekanowski index $\frac{2a}{2a+b+c}$

Problém: každý atribut reprezentuje něco jiného.


Co udělá větší vzdálenost: rozdíl 5kg v atributu *váha* nebo rozdíl 5cm v atributu *výška*.

- ▶ konstruovat metriku s doménovým expertem
- ▶ provést normalizaci – namapovat data na jeden interval, třeba $[0, 1]$

Lineární transformace

$$v_{i,\text{lin.norm}} = \frac{v_i - \min(v_1, \dots, v_n)}{\max(v_1, \dots, v_n) - \min(v_1, \dots, v_n)}$$


```
> vec <- iris[,1]
> max_v <- max(vec)
> min_v <- min(vec)
> min_v
[1] 4.3
> max_v
[1] 7.9
> nvec <- vapply(vec, 0, FUN=function(vi)
                {(vi - min_v)/(max_v-min_v)})
```



Problém: co když pak přijde hodnota, která je mimo interval min–max


Jiný problém: co když je v datech odlehlý bod?

```
> vec[151] <- 150  
> nvec <- vapply(vec, 0, FUN=function(vi)  
  {(vi - min_v)/(max_v-min_v)})  
> plot(vec, nvec)
```



Co s tím: nemapujeme na $[0,1]$ ale na $[a,1-a]$, a hodnoty mimo „vtlačíme“ do $[0, a)$ a $(1 - a, 0]$.

```
> nvec <- vapply(vec, 0, FUN=function(vi)
+   {(vi - min_v)/(max_v-min_v)*(1-2*a)+a})
> plot(vec, nvec, ylim=0:1)
```




Jak teda na to vtlačení:

$$v_{i,\text{norm}} = \begin{cases} 1 - a/v_{i,\text{lin.norm}} & \text{pokud } v_i > u \\ a/(1 - v_{i,\text{lin.norm}}) & \text{pokud } v_i < l \\ v_{i,\text{lin.norm}} \cdot (1 - 2a) + a & \text{jinak} \end{cases}$$

```
the.lin.fun <- function(vi)
{
  (vi - min_v)/(max_v-min_v)
}


the.fun <- function(vi)
{
  if (vi > max_v) return (1 - a * (1/the.lin.fun(vi)))
  if (vi < min_v) return (a * (1/(1 - the.lin.fun(vi)))
  return(the.lin.fun(vi)*(1-2*a)+a)
}
```

```
> plot(-50:50, vapply(-50:50, 0, FUN=the.fun), ylim=0:1)
```



To se celkem podobá simoidě

```
> sig <- function(x) {1 / (1 + exp(-x))}  
> plot(-50:50, vapply(-50:50, 0, FUN=sig))
```



Sigmoida se taky dá použít pro normalizaci, ale předtím je potřeba data prohnat následujícím


$$v_t = \frac{v_i - \mu}{\lambda \cdot \sigma / (2\pi)},$$

kde

- ▶ μ je průměr
- ▶ σ je směrodatná odchylka
- ▶ λ je parametr označující, kolik směrodatných odchylek má dávat lineární odpověď (obvykle se používá $\lambda = 2$)

```
> nvec <- vapply( vec , 0 , FUN=function(x)
+               {(x - mean_v)/(2 * (sd_v / 2) * pi)})
> nnvec <- vapply(nvec , 0 , FUN=sig)
```

```
> plot(vec, nnvec)
```



To je pak známo jako *softmax*