

1 Normalizácia dát

Máme vstupné dáta $X = \{x_1, x_2, \dots, x_N\}$.

1.1 Decimálne škálovanie na interval $< -1, 1 >$

Napište funkciu `decscale(x)`, ktorá transformuje vektor $\mathbf{x}$ vydelením jeho zložiek číslom 10^d , kde d je najmenšie celé číslo také, že platí

$$\forall i \in \{1, \dots, N\} : -1 \leq x_i \leq 1.$$

Napríklad

```
>> decscale([23.5 -5 0])
ans =

    0.2350    -0.0500         0

>> decscale([0.007 -0.02 0.00082])
ans =

    0.0700    -0.2000    0.0082
```

Pomocou príkazu `plot` zobrazte do jedného grafu $\mathbf{x}$ a `decscale(x)` – napr. $\mathbf{x}$ na x -ovú a `decscale(y)` na y -ovú osu.

1.2 Min-max normalizácia na interval $< A, B >$

Napište funkciu `mmscale(x)`, ktorá transformuje vektor $\mathbf{x}$ tak, že jeho zložky lineárne namapuje na interval $< A, B >$. Typicky sa robí min-max normalizácia na interval $< 0, 1 >$ alebo na interval $< -1, 1 >$.

Napríklad

```
>> mmscale([0.12 3 -123], -1, 1)
ans =

    0.95429    1.00000   -1.00000

>> mmscale([0.12 3 -123], 0, 1)
ans =

    0.97714    1.00000    0.00000
```

Pomocou príkazu `plot` zobrazte do jedného grafu $\mathbf{x}$ a `mmscale(x, A, B)` – napr. $\mathbf{x}$ na x -ovú a `decscale(y)` na y -ovú osu.

1.3 Normalizácia podľa smerodatnej odchýlky

Smerodatná odchýlka (standard deviation) je funkcia

$$sd(X) = \sigma_X = \sqrt{\frac{\sum (X - \bar{X})^2}{N - 1}},$$

kde $\bar{X} = \frac{1}{N} \cdot \sum_{i=1}^N x_i$ je stredná hodnota.

Táto normalizácia urobí takú transformáciu, aby dáta mali strednú hodnotu 0 a rozptyl 1.

Napíšte funkciu `sdscale(x)`, ktorá transformuje vektor `x` tak, že jeho zložky budú mať strednú hodnotu 0 a rozptyl 1.

Napríklad

```
>> sdscale([1 2 3])
ans =

    -1         0         1

>> sdscale([-2 2 7])
ans =

   -0.96099   -0.07392    1.03491
```

1.4 Sigmoidálna normalizácia

Sigmoida je funkcia

$$f(x) = \frac{1}{1 + e^{-\lambda x}}, \text{ kde } \lambda > 0 \text{ sa nazýva } \textit{strmost'}$$

Sigmoida má definičný obor $(-\infty, +\infty)$ a obor hodnôt $(0, 1)$.

Jej graf pre $\lambda = 1$ si môžeme zobrazit napr. príkazmi

```
>> x=-10:0.2:10;
>> plot(x,1./(1+exp(-x)))
```

Napíšte funkciu `sigmscale(x,1)`, ktorá transformuje prvky vektora `x` podľa sigmoidy so strmost'ou 1.

Napríklad

```
>> sigmscale(-3:3,2) ans =

    0.00247    0.01799    0.11920    0.50000    0.88080    0.98201    0.99753
```

Naprogramujte aj transformáciu `sigmscale_inv(x,1)` inverznú k transformácii `sigmscale(x,1)`.

1.5 Normalizácia mnohorozmerných dát

Dáta pre dobývanie znalostí sú obvykle tabuľky s mnohými stĺpcami. Keď sa robí normalizácia takýchto dát, tak sa normalizuje celá tabuľka po stĺpcoch. Tu je treba dať pozor na to, že každý stĺpec má iný rozsah hodnôt a bude obecné transformovaný inou funkciou. Vyššie uvedené transformácie boli definované pre riadkové vektory. Naprogramujte nové verzie dekatického škálovania, min-max škálovania, normalizácie podľa smerodatnej odchýlky a sigmoidálnej transformácie s novými názvami `decscalem(x,c)`, `mmscalem(x,A,B,c)`, `sdscalem(x,c)`,

`sigmscalem(x,1,c)`, ktoré majú ako prvý parameter (dvojmernú) maticu `x`. Posledný parameter `c` je riadkový vektor rovnakej dĺžky ako riadky matice `x` a obsahuje iba hodnoty 0 a 1. Príslušná normalizácia sa vykoná na stĺpci `i` iba vtedy, keď `c[i]` je nenulové.

Napríklad

```
>> yy=5*rand(5,3)
yy =

    0.41501    0.33185    1.89638
    2.05899    0.09640    0.80592
    2.66147    4.35444    3.80238
    0.85257    4.59147    2.21583
    2.31878    4.61248    0.05122
```

```
>> decscale(yy,[1 0 1])
ans =

    0.04150    0.33185    0.18964
    0.20590    0.09640    0.08059
    0.26615    4.35444    0.38024
    0.08526    4.59147    0.22158
    0.23188    4.61248    0.00512
```

```
>> mmscalem(yy,-1,1,[1 0 1])
ans =

   -1.00000    0.33185   -0.01622
    0.46362    0.09640   -0.59762
    1.00000    4.35444    1.00000
   -0.61045    4.59147    0.15410
    0.69491    4.61248   -1.00000
```

2 Generovanie testovacích dát

Pre programovanie a testovanie rôznych metód dobývania znalostí je užitočné vedieť generovať dáta so zadanými vlastnosťami a tiež vedieť generovať “náhodné” dáta, resp. náhodne vyberať dáta z danej množiny.

Na generovanie náhodných dát je treba poznať rozloženie pravdepodobnosti (probability distribution) pre dáta. Matica veľkosti $m \times n$ dát s rovnomerným rozložením (uniform distribution) z intervalu A , B sa vygeneruje príkazom

```
>> A=3; B=10;
>> m=3; n=4;
>> (B-A)*rand(m,n)+A
ans =

    3.31198    6.28767    7.37211    8.75329
    5.75145    9.82846    8.29843    3.21501
    7.42435    4.56690    5.99315    6.79303
```

Funkcia **randn** generuje náhodné hodnoty s normálnym rozložením so strednou hodnotou 0 a rozptylom 1 (tj. smerodatnou odchýlkou $\sqrt{1} = 1$). Matica veľkosti $m \times n$ dát s normálnym rozložením (normal distribution) so strednou hodnotou S a rozptylom R (tj. smerodatnou odchýlkou $\sqrt{R}$) sa vygeneruje príkazom

```
>> S=2; R=3;
>> m=3; n=4;
>> sqrt(R)*randn(m,n)+S
ans =

    1.76953    1.02155    2.90496    3.54724
    1.81023    9.41794   -1.39530    3.38295
    4.53440   -2.64642    3.07368    0.76086
```

2.1 Generovanie vektora s dvomi zhlukmi

Napište funkciu **randv2n(n1,S1,R1,n2,S2,R2)**, ktorá vygeneruje vektor (riadkový) obsahujúci $n1$ hodnôt s normálnym rozdelením so strednou hodnotou $S1$ a rozptylom $R1$ a ďalej $n2$ hodnôt s normálnym rozdelením so strednou hodnotou $S2$ a rozptylom $R2$.

Napríklad

```
>> randv2n(3,-10,1,4,10,1)
ans =

    1.0e+01 *

    0.86684    0.97688   -0.94214   -0.85999    1.09027    1.09225   -1.19626
```

Urobte histogram vygenerovaných dát.

2.2 Generovanie zhlukov v 2D

Naprogramujte funkciu **randn2d(p)**, ktorá má ako parameter maticu p tvaru $n \times 5$. Táto funkcia vygeneruje maticu rozmerov $\sum_{i=1}^n p(i) \times 2$ obsahujúcu náhodné body v 2D, pričom $p(i,1)$ hodnôt je zo zhluku s normálnym rozdelením so strednou hodnotou $p(i,2)$ v prvej súradnici a strednou hodnotou $p(i,3)$ v druhej súradnici, rozptylom $p(i,4)$ v prvej súradnici a rozptylom $p(i,5)$ v druhej súradnici (pre $i = 1, \dots, n$).

Napríklad:

```
>> rm=randn2d([6,-10,-10,1,1; 8,10,10,2,2])
rm =

    1.0e+01 *

   -0.81834   -1.08722
    1.24685    0.79264
   -0.92659   -0.99046
   -0.96725   -1.02791
```

```

1.00210  1.14543
1.05893  0.97251
0.99114  1.02167
-1.05398 -0.93580
0.75075  1.27756
-1.03174 -1.05069
0.90385  0.86900
0.95572  0.85197
0.99392  0.95680
-0.94696 -1.15904

```

Zobrazte vygenerované zhluky do 2D grafu.

2.3 Generovanie vzorky z dát

Navrhните funkciu `selectk(x,k)`, ktorá z matice `x` náhodne vyberie `k` riadkov.

Napríklad:

```

>> rm=rand(8,2)
rm =

0.02559  0.73449
0.45501  0.37769
0.50644  0.09478
0.31154  0.12610
0.72651  0.93408
0.06366  0.83468
0.91405  0.95055
0.39877  0.00754

>> srm=selectk(rm,4)
srm =

0.50644  0.09478
0.06366  0.83468
0.45501  0.37769
0.31154  0.12610

```

Zobazte pôvodné a vybrané dáta do grafu rozdielnymi farbami alebo značkami.

2.4 Náhodné rozdelenie dát do skupín

Naprogramujte funkciu `rearrange(M)`, ktorá náhodne rozdelí riadky matice `M` do skupín veľkosti `k` (posledná skupina môže mať počet prvkov menší než `k`). Výstupom je matica s náhodne permutovanými riadkami, kde i -ta skupina sú riadky od $(i-1)k+1$ do $\max(ik, n)$, kde n je počet riadkov matice.

Napríklad:

```

>> a=rand(6,3)
a =

```

```

0.18244 0.48563 0.15539
0.55104 0.74847 0.55122
0.95554 0.64857 0.56828
0.12789 0.43557 0.76303
0.80228 0.25556 0.74825
0.07529 0.16154 0.42594

>> rearrange(a)
ans =

0.07529 0.16154 0.42594
0.55104 0.74847 0.55122
0.95554 0.64857 0.56828
0.18244 0.48563 0.15539
0.80228 0.25556 0.74825
0.12789 0.43557 0.76303

```

3 Analýza atribútu

Využite zobrazenie hodnôt vhodným zobrazením a jednoduché štatistické atribúty ako je priemer a rozptyl na analýzu hodnôt atribútu, ktorý je vo vektore, ktorý získate volaním funkcie `dataa` zo súboru <http://ksvi.mff.cuni.cz/~mraz/datamining/dataa.m>. Pomohla by zhluková analýza?

4 Kontingenčné tabuľky, χ^2 a Fisherov test

Pri cvičných zoskokoch boli parašutisti rozdelení do dvoch skupín *A* a *B*, ktoré skákali na dvoch rôznych miestach. V jednej skupine bolo mnoho zranených. Celkové počty sú uvedené v nasledujúcej tabuľke:

	zranených	zdravých	Celkom
Skupina <i>A</i>	2	38	40
Skupina <i>B</i>	5	10	15
Celkom	7	48	55

Table 1: Kontingenčná tabuľka

Spočítajte χ^2 -test a Fisherov test na hladine významnosti $\alpha = 0.05$. Odpovedzte na otázku, či rozdiely medzi skupinami sú náhodné, alebo nie.