

Úloha 3 – EM algoritmus

- Seznamte se s daty v souboru `height.csv`, který obsahuje tělesnou výšku vzorku 100 lidí, Američanů ve věku mezi 20 a 29 lety. Kromě výšky lidí (1. sloupec) obsahují data i jejich pohlaví (2. sloupec). Každý záznam tvoří jeden řádek tabulky.
- Prohlédněte si dokumentaci k přiložené funkci `dataplot(data)`, která načtená data vykreslí do grafu: `>> data = csvread('height.csv.txt'); dataplot(data);`
- Implementujte EM algoritmus pro maximum-likelihood optimalizaci parametrů směsi dvou normálních rozdělení. Popis algoritmu naleznete ve třetí přednášce (str. 21-24).
 - Vstupem algoritmu bude první sloupec načtených dat (druhý sloupec můžete použít pro zpětnou kontrolu). Vhodně zvolte počáteční parametry obou rozložení.
 - Pokud Váš algoritmus vrátí matici 2×2 ve formátu

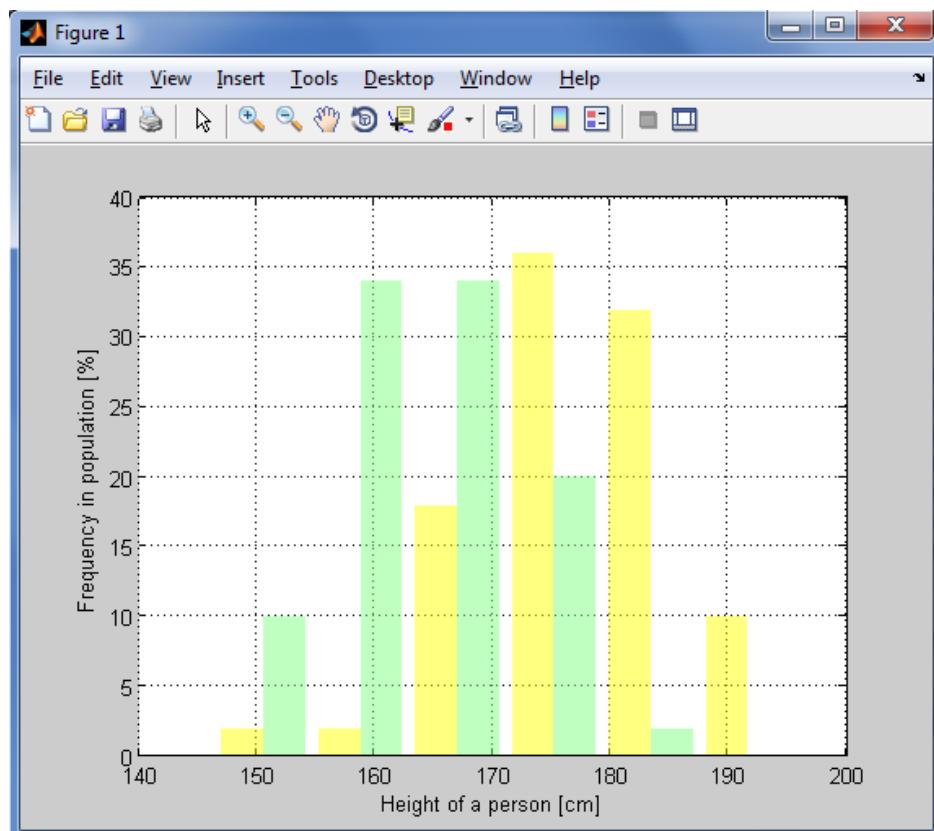
$$\text{params} = \begin{pmatrix} \mu_{\text{ženy}} & \sigma_{\text{ženy}} \\ \mu_{\text{muži}} & \sigma_{\text{muži}} \end{pmatrix}$$

můžete pro vykreslení obou rozdělení použít příkaz `>> dataplot(data, params);`

- Vyvořte protokol o rozsahu cca. 1 strany A4, která shrne Vaši práci a analyzuje výsledky.
Doporučený obsah:
 - grafy obou gaussovských rozložení v několika počátečních iteracích algoritmu a stav po konvergenci
 - počet iterací algoritmu (dochází-li k velkému rozptylu hodnot pro různá počáteční nastavení, spusťte algoritmus několikrát a výsledek vyhodnotte statisticky)
 - diskuze o vlivu prvního přiřazení parametrů na jejich výsledné hodnoty
 - rozbor, zda lze mezi výškou mužů a žen pozorovat statisticky významný rozdíl (využijte druhý sloupec vstupních dat a závěry z předchozích bodů)
 - poznámky k implementaci

Graf načtených dat:

```
>> data = csvread('height.csv.txt'); dataplot(data);
```



Implementace v aplikaci Matlab:

```

function [ vysledek ] = em( data )
% em(data(:,1)) = dle zadani pouzijeme prvni sloupec dat
% data = csvread('height.csv.txt'); = inicializace dat

% inicializace pocatecnich parametru podle zadani ulohy
uMuz = 200.0;
uZena = 150.0;
oMuz = 10.0;
oZena = 10.0;
convergence = 0.00001; % convergence = presnost algoritmu
nextStep = 1;
pocetIteraci = 0;

while nextStep == 1
    hodnotaM = uMuz;
    hodnotaZ = uZena;
    pocetIteraci = pocetIteraci + 1; % pocet iteraci
    [uMuz, uZena, oMuz, oZena] = emIteration(data, uMuz, uZena, oMuz, oZena);
    if((abs(hodnotaM - uMuz) < convergence) && (abs(hodnotaZ - uZena) < convergence))
        nextStep = 0;
    end

    % nastaveni iteraci
    % if (pocetIteraci == 10)
    % nextStep = 0;
    % end
end

fprintf('Number of iterations: %d\n', pocetIteraci);
vysledek = [uMuz oMuz; uZena oZena];
return
end

% em algoritmus
function [uMuz, uZena, oMuz, oZena] = emIteration(data, uMuzIt, uZenaIt,
oMuzIt, oZenaIt)
uMuz = uMuzIt;
uZena = uZenaIt;
oMuz = oMuzIt;
oZena = oZenaIt;

length = size(data, 1); % pocet hodnot
probabilities1 = zeros(1, length);
probabilities2 = zeros(1, length);

% expectation krok - viz vzorec z prednasky
for i = 1:length
    temp1 = expectationForDataPart1(data(i), uMuz, oMuz);
    temp2 = expectationForDataPart1(data(i), uZena, oZena);
    probabilities1(i) = temp1 / (temp1 + temp2);
    probabilities2(i) = (1.0 - probabilities1(1, i));
end

% maximization krok - viz vzorec z prednasky
uMuz = (probabilities1 * data) / sum(probabilities1);
uZena = (probabilities2 * data) / sum(probabilities2);
oMuz = sqrt((probabilities1 * ((data - uMuz).^2.0)) / sum(probabilities1));
oZena = sqrt((probabilities2 * ((data - uZena).^2.0)) /
sum(probabilities2));

```

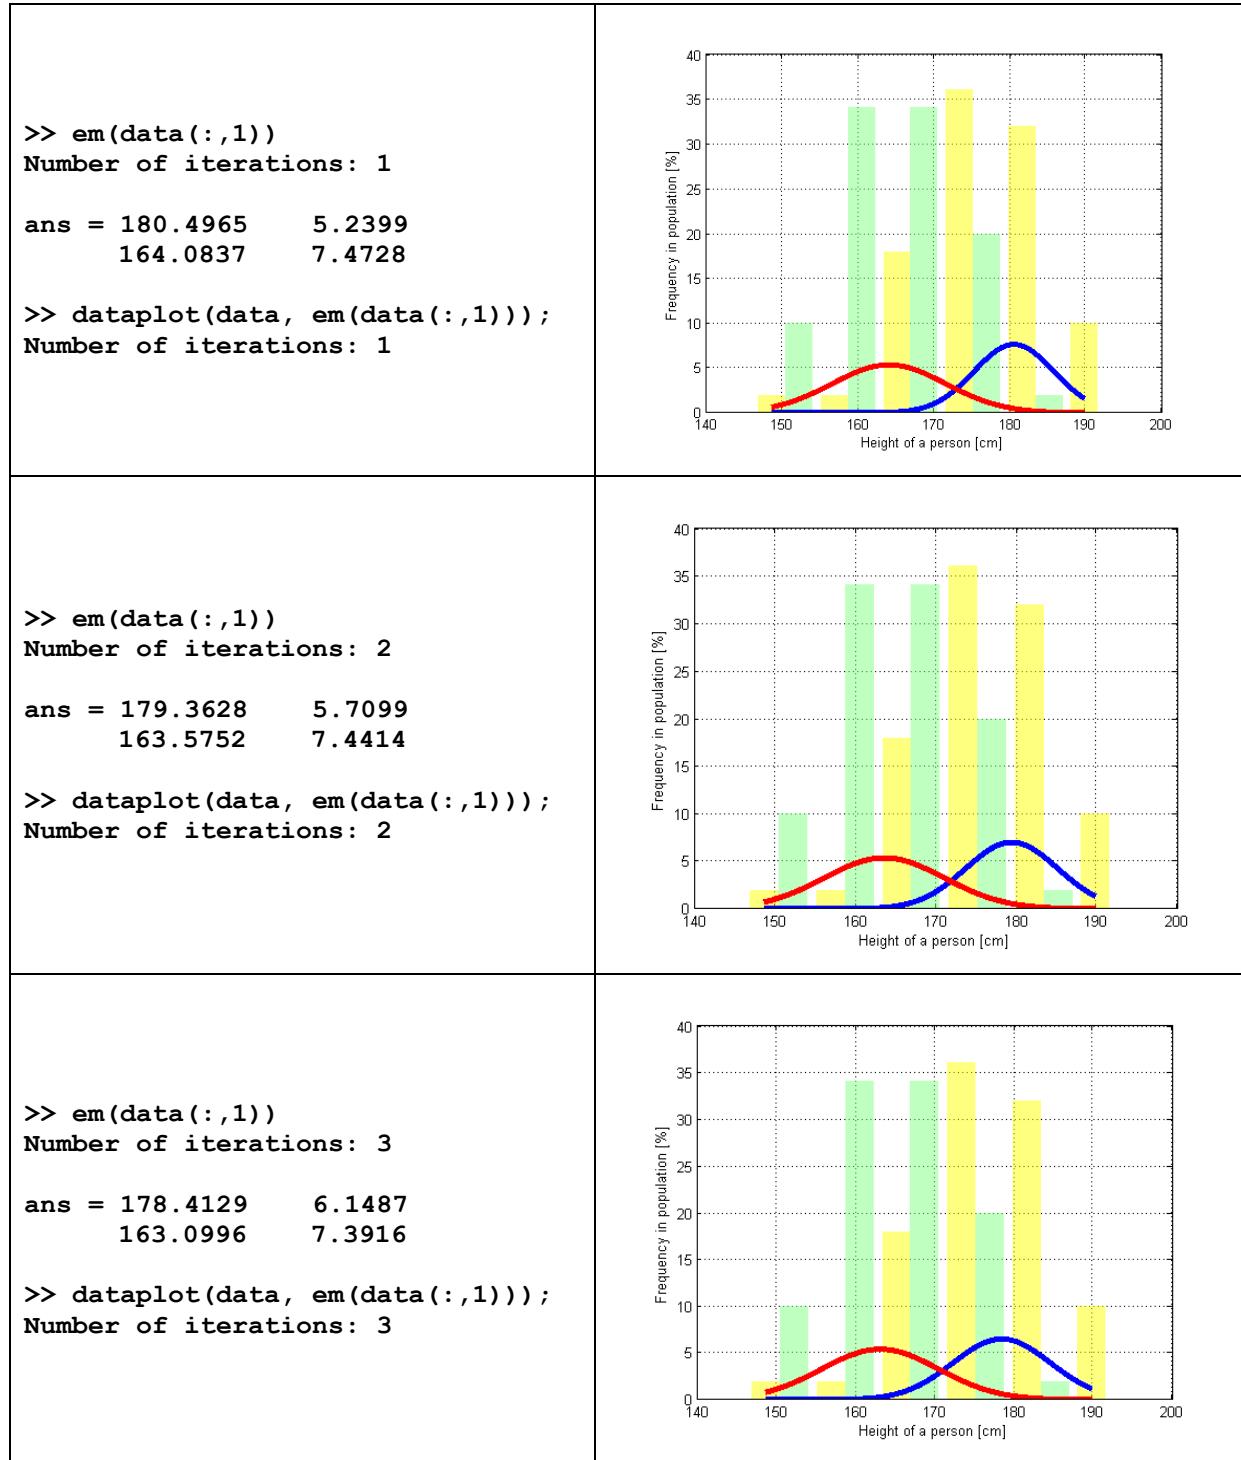
```

return
end

function [ vysledek ] = expectationForDataPart1(data, mean, stdDev)
% pomocna fce pro vypocet expectation kroku
vysledek = (exp(-(((data - mean)^2.0) / (2.0 * stdDev^2.0))) * 0.5) /
sqrt(2.0 * pi * stdDev);
return
end

```

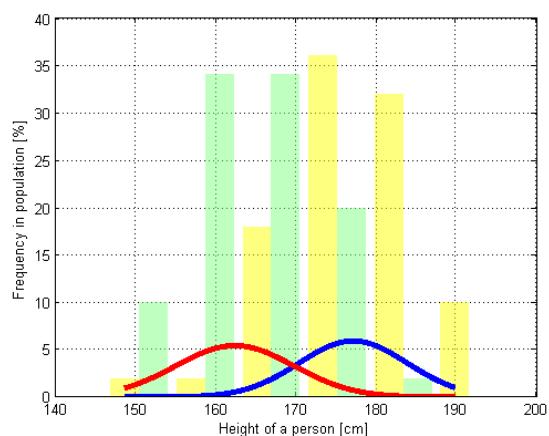
Přehled změn podle počtu iterací:



```
>> em(data(:,1))
Number of iterations: 5

ans = 177.0906      6.7379
     162.3929      7.3481

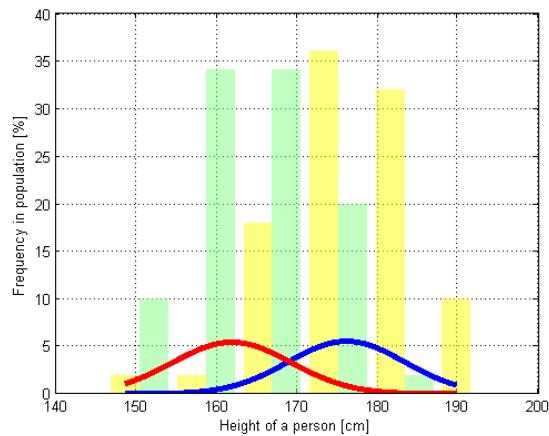
>> dataplot(data, em(data(:,1)));
Number of iterations: 5
```



```
>> em(data(:,1))
Number of iterations: 10

ans = 176.1025      7.2212
     161.9127      7.3626

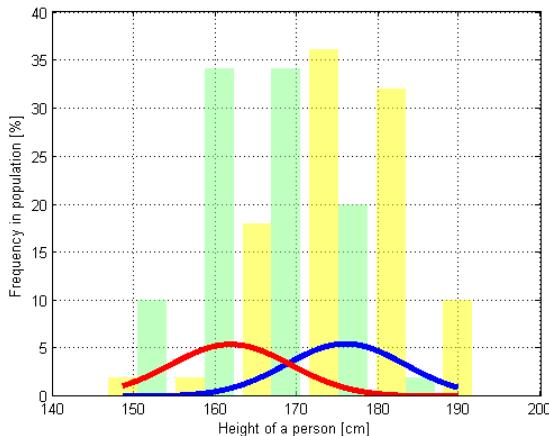
>> dataplot(data, em(data(:,1)));
Number of iterations: 10
```



```
>> em(data(:,1))
Number of iterations: 15

ans = 175.9800      7.2977
     161.8967      7.3900

>> dataplot(data, em(data(:,1)));
Number of iterations: 15
```



<pre>>> em(data(:,1)) Number of iterations: 25 ans = 175.9579 7.3153 161.9070 7.4034 >> dataplot(data, em(data(:,1))); Number of iterations: 25</pre>	<p>A histogram showing the frequency of people's heights in a population. The x-axis represents height in cm from 140 to 200, and the y-axis represents frequency in percentage from 0 to 40. Two overlapping Gaussian curves are plotted: a red curve peaking around 168 cm and a blue curve peaking around 172 cm.</p>
<pre>>> em(data(:,1)) Number of iterations: 35 ans = 175.9569 7.3163 161.9081 7.4045 >> dataplot(data, em(data(:,1))); Number of iterations: 35</pre>	<p>A histogram showing the frequency of people's heights in a population. The x-axis represents height in cm from 140 to 200, and the y-axis represents frequency in percentage from 0 to 40. Two overlapping Gaussian curves are plotted: a red curve peaking around 168 cm and a blue curve peaking around 172 cm. The peaks are slightly more defined than in the first plot.</p>
<p>Stav po konvergenci:</p> <pre>>> em(data(:,1)) Number of iterations: 39 ans = 175.9568 7.3164 161.9082 7.4045 >> dataplot(data, em(data(:,1))); Number of iterations: 39</pre>	<p>A histogram showing the frequency of people's heights in a population. The x-axis represents height in cm from 140 to 200, and the y-axis represents frequency in percentage from 0 to 40. Two overlapping Gaussian curves are plotted: a red curve peaking around 168 cm and a blue curve peaking around 172 cm. The peaks are very well-defined and centered.</p>

Pokud algoritmus spustíme podle počtu iterací, dochází k výrazným změnám u iterací 1 - 5. Od 10té iterace již nejsou markatní rozdíly ve výsledných křivkách. Z toho vyplývá, že čím více iterací provedeme, tím přesnější výsledek získáme.

Při zadání vstupních dat muži = 200 a ženy = 150 zjistíme po první iteraci, že max výška u mužů dosahuje 180,5 a u žen 164. Průměrná výška mužů a žen pak činí 172,25.

Po konvergenci činí max výška u mužů cca 176 a u žen na 161,9. Tzn. průměrná výška činí 168,95. Z toho vyplývá, že čím více dat je zpracováno, tím více dochází ke snížení rozdílu ve výšce mužů a žen, říčemž větší rozdíl je v max. výšce mužů, který se snížil ze 180,5 na 176, zatímco u žen dochází k poklesu ze 164 na 161,9.