

Vytěžování dat, cvičení 1: Úvod do Matlabu

Michael Anděl, Miroslav Čepěk

Fakulta elektrotechnická, ČVUT



EVROPSKÝ UNIE

Kontakty na přednášející a cvičící

Jiří Kléma

email : klema@fel.cvut.cz

Filip Železný

Místnost: KN-E 432

email : zelezny@fel.cvut.cz

Místnost: KN-E 201

Michael Anděl

email : andelmi2@fel.cvut.cz

Ondřej Pluskal

Místnost: KN-E 432

email : ondra.pluskal@gmail.com

Místnost: KN-E 435

Konzultace jsou možné po předchozí domluvě. Preferovaná forma konzultací je přes diskusní fórum předmětu na <https://cw.felk.cvut.cz/forum/forum-164.html>.

Obsah dnešního cvičení

Úvod do předmětu

Proč Matlab?

Programování pro Matlab

Zápočtová úloha

Byli bychom rádi, kdybyste si z předmětu odnesli

- ▶ jaké jsou základní úlohy ve vytěžování dat (tím nemyslíme tento předmět),
- ▶ jak základní metody pro tvorbu modelů,
- ▶ představu o vyhodnocování přesnosti a úspěšnosti modelů,
- ▶ širší povědomí o data miningu.

Organizace cvičení a požadavky na zápočet

- ▶ Stránky předmětu: <https://cw.felk.cvut.cz/doku.php/courses/a7b36vyd/start>
- ▶ Náplň cvičení bude odevzdání domácí úlohy a konzultace k zadané domácí úloze. Tj. jejich obsah budou tvořit především dotazy na probranou látku na přednáškách a zadané úlohy.
- ▶ Na začátku každého cvičení bude zadána jedna zápočtová úloha týkající se látky z poslední přednášky.
- ▶ Z každé úlohy se vypracovává krátký protokol, rozsahem přibližně jedna strana A4.
- ▶ Celkem bude 11 zápočtových úloh a všechny je musíte odevzdat. Za každou úlohu můžete získat až 5 bodů.
- ▶ Dohromady musíte za úlohy získat alespoň 30 bodů.

- ▶ Každý domácí úkol (kromě prvních dvou) bude na procvičení/vyzkoušení látky probírané na přednášce \Rightarrow chod'te na přednášky!
- ▶ K získání zápočtu musíte odevzdat všech 11 domácích úkolů.
 - ▶ Na vypracování každého úkolu bude jeden týden, pokud nebude řečeno jinak.
 - ▶ Zprávu budete odevzdávat přes upload systém na stránkách předmětu.
 - ▶ Deadline na odevzdání je půlnoc z pondělí na úterý daného týdne.
- ▶ V případě **závažných** důvodů může cvičící povolit pozdní odevzdání. Problémy řešte co nejdřív!! (A pokud možno, dopředu).

- ▶ Zpráva musí být v upload systému na stránkách předmětu do zadaného deadlinu.
- ▶ Pokud má úloha i programovací část, můžete ji ladit ještě i po deadlinu až do odevzdání na cvičení.
- ▶ Stejně tak, pokud při odevzdání na cvičení vyplují na povrch drobné nedostatky, máte šanci je opravit přímo na cvičení bez ztráty bodů.
- ▶ Body se udělují stylem SPLNĚNO/NESPLNĚNO.
 - ▶ Splnění a odevzdání včas – 5 bodů.
 - ▶ Splnění a odevzdání s týdením zpožděním – 2 body.
 - ▶ Splnění a odevzdání s dvoutýdenním zpožděním – 0 body (ale stále nárok na zápočet).
 - ▶ Později – neudělení zápočtu.

- ▶ Body ze cvičení si ponese ke zkoušce, kde vám budou k užítku :).
- ▶ Zkouška bude hlavně písemná – z písemky můžete získat až 45 bodů.

Výsledná známka bude dána součtem bodů ze zkouškové písemky a cvičení:

ECTS známka	A	B	C	D	E	F
Počet bodů	100-90	89-80	79-70	69-60	59-50	50-0

Proč probíhá Matlab?

- ▶ Matlab je SW pro vědecko-technické výpočty a de facto průmyslový standard v mnoha odvětvích.
- ▶ Vhodný pro rychlé prototypování a zkoušení aplikací.
- ▶ Obsahuje skriptovací jazyk se spoustou knihoven pro různé oblasti (včetně vytěžování dat).
- ▶ Matlab je v tomto předmětu kompromis mezi "klikacími" nástroji typu RapidMiner a programováním v jazycích typu Java.
- ▶ Dovolí nám hrát si s implementací algoritmů, ale spoustu věcí řeší interně za vás.

Kde získat Matlab?

- ▶ FEL má multilicenci, kterou můžete využít.
- ▶ Kopii instalačního DVD můžete získat na <http://www.fel.cvut.cz/user-info/matlab.html>
- ▶ Zde se musíte přihlásit hlavním přístupovým heslem a pak už můžete stahovat a instalovat.

Základní uživatelské rozhraní

The screenshot displays the MATLAB 7.11.0 (R2010b) user interface. The top menu bar includes File, Edit, Debug, Desktop, Window, and Help. The 'Current Folder' path is shown as `/Users/cepekml/Documents/MATLAB`, which is highlighted with a red box and labeled 'Aktuální pracovní adresář'. The left sidebar shows the 'Current Folder' containing a file named `factorial.m`, with the text 'Obsah aktuálního adresáře' overlaid. The central 'Command Window' shows the following code and output:

```
>> x = [1 1 2 2 4 5 6];
>> mode(x)

ans =

     1

>> x = [1 1 2 2 4 5 6 6 6];
>> mode(x)

ans =

     6
```

The text 'Příkazový řádek pro zadávání příkazů a jejich výstup' is overlaid on the Command Window. Below the code, the help text for the `mode` function is visible, including the note: 'See also [timeseries/mean](#), [timeseries/igr](#), [timeseries/std](#)'. The right sidebar shows the 'Workspace' with variables A, B, C, ans, i, row, sl, str, x, and y, with the text 'Aktuálně definované proměnné a jejich hodnoty (zkuste dvojklik)' overlaid. The bottom right shows the 'Command History' with the following commands:

```
h(1) find(a > 0.5)
fprintf(' %d', 5)
disp(5)
disp(x)
for i = [ 1 6 10000 4 3.1415 2.7 1.41
disp(i); end
factorial(5)
help ce Historie příkazů
A > 0.5
help mode
x = [1 1 2 2 4 5 6];
mode(x)
x = [1 1 2 2 4 5 6 6 6];
mode(x)
```

Do příkazového okna zkuste zadat následující příkazy. Jaký je jejich význam a co je výsledkem?

- ▶ $1 + 5$
- ▶ Ukládá se někam výsledek?
- ▶ $x = 3$
- ▶ $y = 1 * 6$
- ▶ $x + y$
- ▶ $z = x + y$
- ▶ $z = x + y;$
- ▶ Jaký je rozdíl mezi předchozími dvěma příkazy?

- ▶ Hlavní síla Matlabu spočívá v práci s maticemi.
- ▶ Jak vypadají matice z následujících příkazů?

A = [1 2; 3 4; 5 6]

B = [1 2 3; 4 5 6]

$$A = \begin{pmatrix} 1 & 2 \\ 3 & 4 \\ 5 & 6 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{pmatrix}$$

- ▶ Jaké znáte maticové operace?
- ▶ Maticové sčítání, odčítání, násobení, dělení, transpozice
- ▶ $C = [7 \ 8; \ 9 \ 10; \ 11 \ 12]$
- ▶ $A + C$
- ▶ $A * B$
- ▶ $A .* C$
- ▶ Jak se liší výsledky posledních dvou příkazů?
- ▶ Co dělá A' ?

- ▶ Matice náhodných čísel `rand(<počet prvků v 1. dimenzi>, <v 2. dimenzi>, ...)`
 - ▶ například `A = rand(10, 5)`
- ▶ Velikost matice, počet prvků v jednotlivých dimenzích – `size(A)`
- ▶ Matice samých nul – `zeros(10, 6)`
- ▶ Inverzní matice – `inv(A)`
- ▶ Vlastní čísla – `eig(A)`
- ▶ Determinant – `det(A)`
- ▶ Indikace splnění podmínky – `A > 0.5`
- ▶ Vybere indexy z matice na základě podmínky – `find(A > 0.5)`

Existuje několik možností získání nápovědy pro příkaz Matlabu.

- ▶ Jednoduchá textová nápověda – příkaz `help <příkaz>`
- ▶ Hypertextová nápověda – příkaz `doc <příkaz>`
- ▶ Mathworld Knowledge Base –
<http://www.mathworks.com/help/techdoc/>

A co vektory?

- ▶ Vektory jsou matice, které mají jen jeden řádek/sloupec.
- ▶ Vytvořte řádkový a sloupcový vektor hodnot 1, 2, 3, 4, 5, 6.
- ▶ `row = [1 2 3 4 5 6]`
- ▶ `s1 = [1; 2; 3; 4; 5; 6]`
- ▶ Jak vytvořím z řádkového vektoru sloupcový?
- ▶ Transpozicí – `row'`

Pokud potřebujete vytvořit posloupnost čísel, můžete využít příslušný operátor ":" (dvojtečka).

Pomocí něj vygeneruje vektor, který obsahuje posloupnost čísel v zadaném rozmezí – zkuste

- ▶ `[1:10]`; `[-5:5]`; `[5.4:15.6]`
- ▶ můžete zadat i krok, se kterým se posloupnost mění. Zkuste: `[1:0.5:10]`; `[5:-1:5]`; `[5.4:0.2:15.6]`

Zopakujte `A = rand(10, 5)`, ať máme všichni stejné rozměry matice.

- ▶ Přístup k jednomu konkrétnímu prvku – `A(1,2)`
- ▶ **POZOR** – indexy se číslují od **1**!
- ▶ Přístup k podmaticím – uvedu rozsahy indexů, které chci v mít podmatici `A(3:5, 1:3)`
- ▶ Místo čísel můžu uvést i vektory indexů, které chci zobrazit.
- ▶ Zkuste zobrazit prvky ve řádcích 1., 5., 3., 8. a sloupcích 3., 2., 1.
- ▶ `x = [1 5 3 8]; y = [3 2 1]; A(x,y)`

Přiřazování hodnot do matice

- ▶ Úplně stejně jako výběr prvků na minulém slajdu, jen výběr umístím na levou stranu přiřazení.
- ▶ Přiřazení jedné hodnoty – přiřaďte 10 do levého horního rohu matice.
- ▶ $A(1,1) = 10$
- ▶ Přiřazení do podmatice – přiřaďte hodnoty 1, 2, 3, 4 na souřadnice (2,2), (2,4), (4,2), (4,4)
- ▶ $x=[2 \ 4]$; $y=[2 \ 4]$; $A(x,y) = [1 \ 3; 2 \ 4]$

- ▶ V Matlabu, stejně jako v jiných skriptovacích jazycích, proměnné nemají pevný datový typ.
- ▶ Základní datové typy jsou:
 - ▶ Čísla, Logické hodnoty, Řetězce
 - ▶ Matice – matice hodnot jednoho datového typu
 - ▶ Struktury – skupina několika pojmenovaných hodnot zabalených do jedné proměnné
 - ▶ Buňková pole (Cell arrays) – pole hodnotu různých datových typů
 - ▶ Odkazy (Handles)
 - ▶ Objekty

Více o datových typech se lze dozvědět na http://www.mathworks.com/help/techdoc/matlab_prog/f2-43934.html

Doteď jsme zkoušeli interaktivní práci se systémem Matlab. Teď zkusíme programování.

Programy se zadávají do tzv. M-souborů (M-file) což je jen textový soubor s koncovkou `.m`. Existují dva typy M-souborů

- ▶ Skripty – obsahují jen posloupnost příkazů Matlabu,
- ▶ Soubory definující funkci – obsahuje definici funkce, kterou lze využít při interaktivní práci s Matlabem nebo v jiných M-souborech.

Pro editaci obou typů M-souborů můžete použít:

- ▶ libovolný textový editor,
- ▶ editor integrovaný přímo do Matlabu.

My použijeme druhou možnost. Interní editor se spouští buď příkazem `edit` nebo z menu `File > New Script` resp. `File > New Function`.

Základní struktura funkce vypadá takto:

```
function [soucet,rozdil] = SlozitaFunkce(a,b)
%
% Funkce se jmenuje SlozitaFunkce a ma dva vstupni
% parametry - a, b. A dva vystupni parametry -
% soucet, rozdil.
% Tohle je help k funkci SlozitaFunkce. Vypisuje se
% zadanim prikazu 'help SlozitaFunkce'.
%
%Naplneni vystupniho parametru se deje prirazenim
    soucet = a+b;
    rozdil = a-b;
end % Nepovinne end
```

Funkce **musí** být uložena v souboru slozitafunkce.m.

- ▶ Funkci můžete zavolat pomocí jejího jména.
- ▶ `[s, r] = slozitafunkce(10, 4)`
- ▶ Jak Matlab zjistí, kterou funkci voláte?
 - ▶ Matlab se podívá do aktuálního adresáře, zda v aktuálním adresáři existuje soubor `slozitafunkce.m`
 - ▶ Pokud Matlab funkci nenajde v aktuálním adresáři, podívá se na vnitřní proměnné `PATH` na seznam adresářů, které se mají prohledávat a zkusí, zda některý z nich funkci neobsahuje.
- ▶ Z toho plyne, že je důležité, ve kterém adresáři se nacházíte :).

Provádění funkce můžete ovlivnit pomocí standardních konstrukcí, které znáte z jiných programovacích jazyků.

- ▶ Podmínky
 - ▶ if – then – else
 - ▶ switch – case
- ▶ Cykly
 - ▶ for
 - ▶ while

if – then – else

```
if x > 11
    disp('x je vetsi nez 11.');
```

elseif x < 5

```
    disp('x je mensi nez 11 a take mensi nez 5.')
```

else

```
    disp('Je to nejak uplne jinak.');
```

end

switch – case

```
switch x
    case {0, 1, 2, 3}
        disp('x je v intervalu 0-3.');
```

case 4

```
        disp('x je 4.');
```

otherwise

```
        disp('x je uplne jine.')
```

end

For cyklus funguje trochu jinak než jste zvyklí z Javy. For cyklus v Matlabu iteruje přes všechny hodnoty vektoru.

```
for i = 1:10
    fprintf('%d ',i); %muzete pouzit take disp(i)
end
```

```
for i = [1 6 10000 4 3.1415 2.7 1.41]
    disp(i);
end
```

POZOR – použití cyklů je extrémně nevýhodné, protože Matlab parsuje každý řádek znovu ⇒ pokud můžete zkuste cykly obejít (například vektorovými nebo maticovými operacemi).

While cyklus je mnohem blíží tomu, co znáte z jiných jazyků.

```
i = 1;
while i < 10
    fprintf('%d', i);
    i = i+1;
end
```

Existují i příkazy na přerušení cyklů

- ▶ break – ukončuje cyklus if $i = 5$, break, end
- ▶ continue – přeskakuje zbytek iterace if $i = 5$, continue, end

Příklad - faktorial

```
function fac = factorial(n)
if n < 0
    disp('n musi byt vetsi nez 0!');
    fac = 0;
    return;
end
if n == 0
    fac = 1;
    return;
end
fac = 1;
for i = 1:n
    fac = fac * i;
end
end
```

1. zápočtová úloha (I)

Zadání – vytvořte v Matlabu:

- ▶ funkci `fib_arr(array)`, která pro všechny prvky ve vektoru `array` spočítá fibonacciho hodnotu a vrátí pole těchto hodnot.
- ▶ funkci `stat_props(filename)`, která načte zadaný soubor ve formátu CSV a pro každý **řádek** hodnot vypíše maximum, minimum, medián, průměr, rozptyl, stření hodnotu.

Použití všech funkcí Matlabu je samozřejmě dovoleno!

1. zápočtová úloha (II)

Protokol z první úlohy je dobrovolný. Povinný v případě že budete chtít hodnocení dopředu, nebudete-li se moct dostavit na příští cvičení.

Zde jsou odkazy na další výukové materiály o Matlabu

- ▶ <http://labe.felk.cvut.cz/~posik/y33aui/uvod-do-matlabu/>
- ▶ http://www.mathworks.com/help/techdoc/matlab_product_page.html
- ▶ <http://www.mathworks.com/moler/intro.pdf>
- ▶ <http://www.maths.dundee.ac.uk/~ftp/na-reports/MatlabNotes.pdf>
- ▶ a mnoho dalších...