

Architektura dużych projektów bioinformatycznych

Pakiety do obliczeń: naukowych,
Inżynierskich i statystycznych
Przegląd i porównanie

Bartek Wilczyński

14.11.2015

Plan na dziś

- Pakiety do obliczeń: przegląd zastosowań
- różnice w zapotrzebowaniu: naukowcy, inżynierowie, statystycy/medycy
- Matlab/octave/scipy
- S-Plus/SPSS/projekt R
- Mathematica/Maxima/Sage
- Pakiety komercyjne vs. Open Source
- Excel?

Typowi użytkownicy pakietów obliczeniowych

- Inżynierowie i projektanci (budownictwo, lotnictwo, motoryzacja, itp.)
- Naukowcy doświadczalni (fizycy, chemicy, materiałoznawcy, itp.)
- Statystycy (zastosowania w medycynie, ekonomii, biologii molekularnej, psychologii, socjologii, ubezpieczeniach, itp.)
- Matematycy (przede wszystkim matematyka stosowana)

Obliczenia naukowe

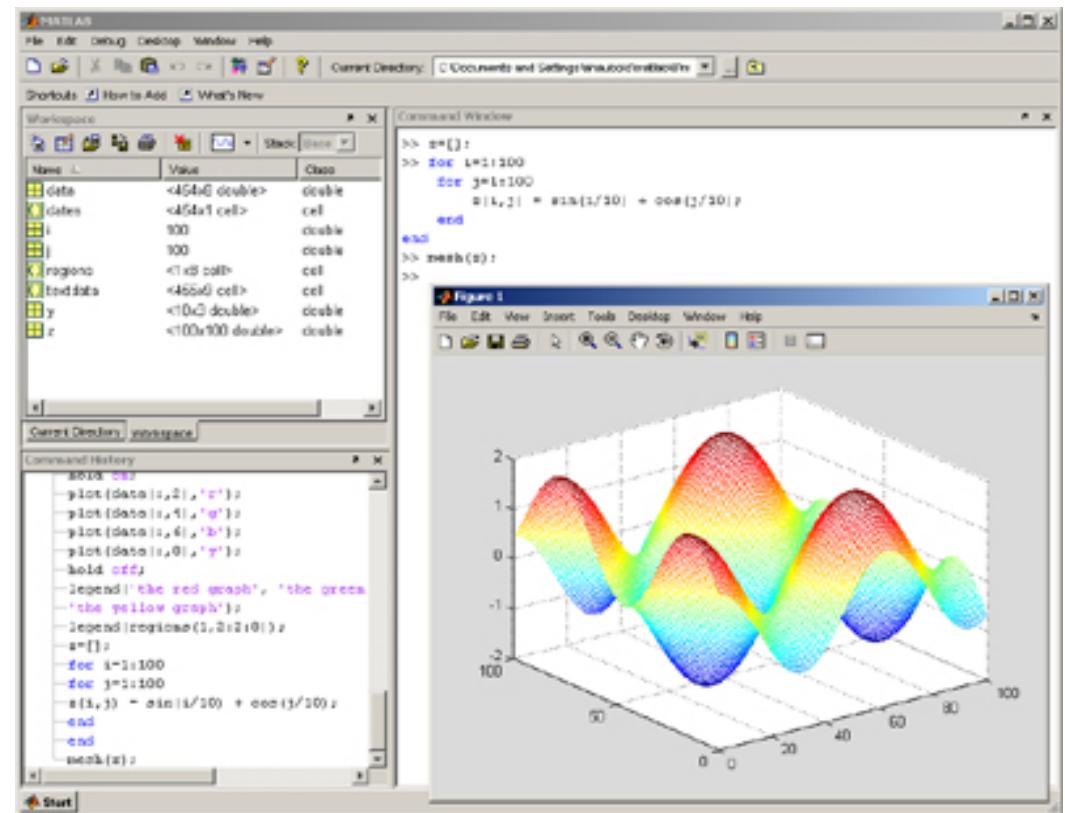
- Komputer jako “potężniejszy kalkulator”
- W zasadzie wszystko można zaprogramować samemu, ale każdemu mogą się przydać:
 - Interfejs użytkownika łatwiejszy niż typowego kompilatora
 - Możliwość zaawansowanej grafiki
 - Dobrze przetestowane standardowe procedury
 - Interfejsy do urządzeń
 - Wsparcie fachowców

Matlab i pakiety “inżynierskie”

- Rozwijany w latach 70'tych przez Cleve Moler'a jako narzędzie dla studentów informatyki, aby nie musieli używać zaawansowanych bibliotek fortranu
- Firma mathworks powstaje w 1984 i wydaje pierwszą wersję Matlab'a
- Najpopularniejszy wśród inżynierów, dobre całki numeryczne, rozwiązywanie równań i wykresy (również 3d)
- Bardzo popularny także do przetwarzania sygnałów i symulacji (simulink)
- Licencja komercyjna – niedrogi dla studentów, droższy dla uczelni, bardzo drogi dla przemysłu

Toolbox'y Matlab'a

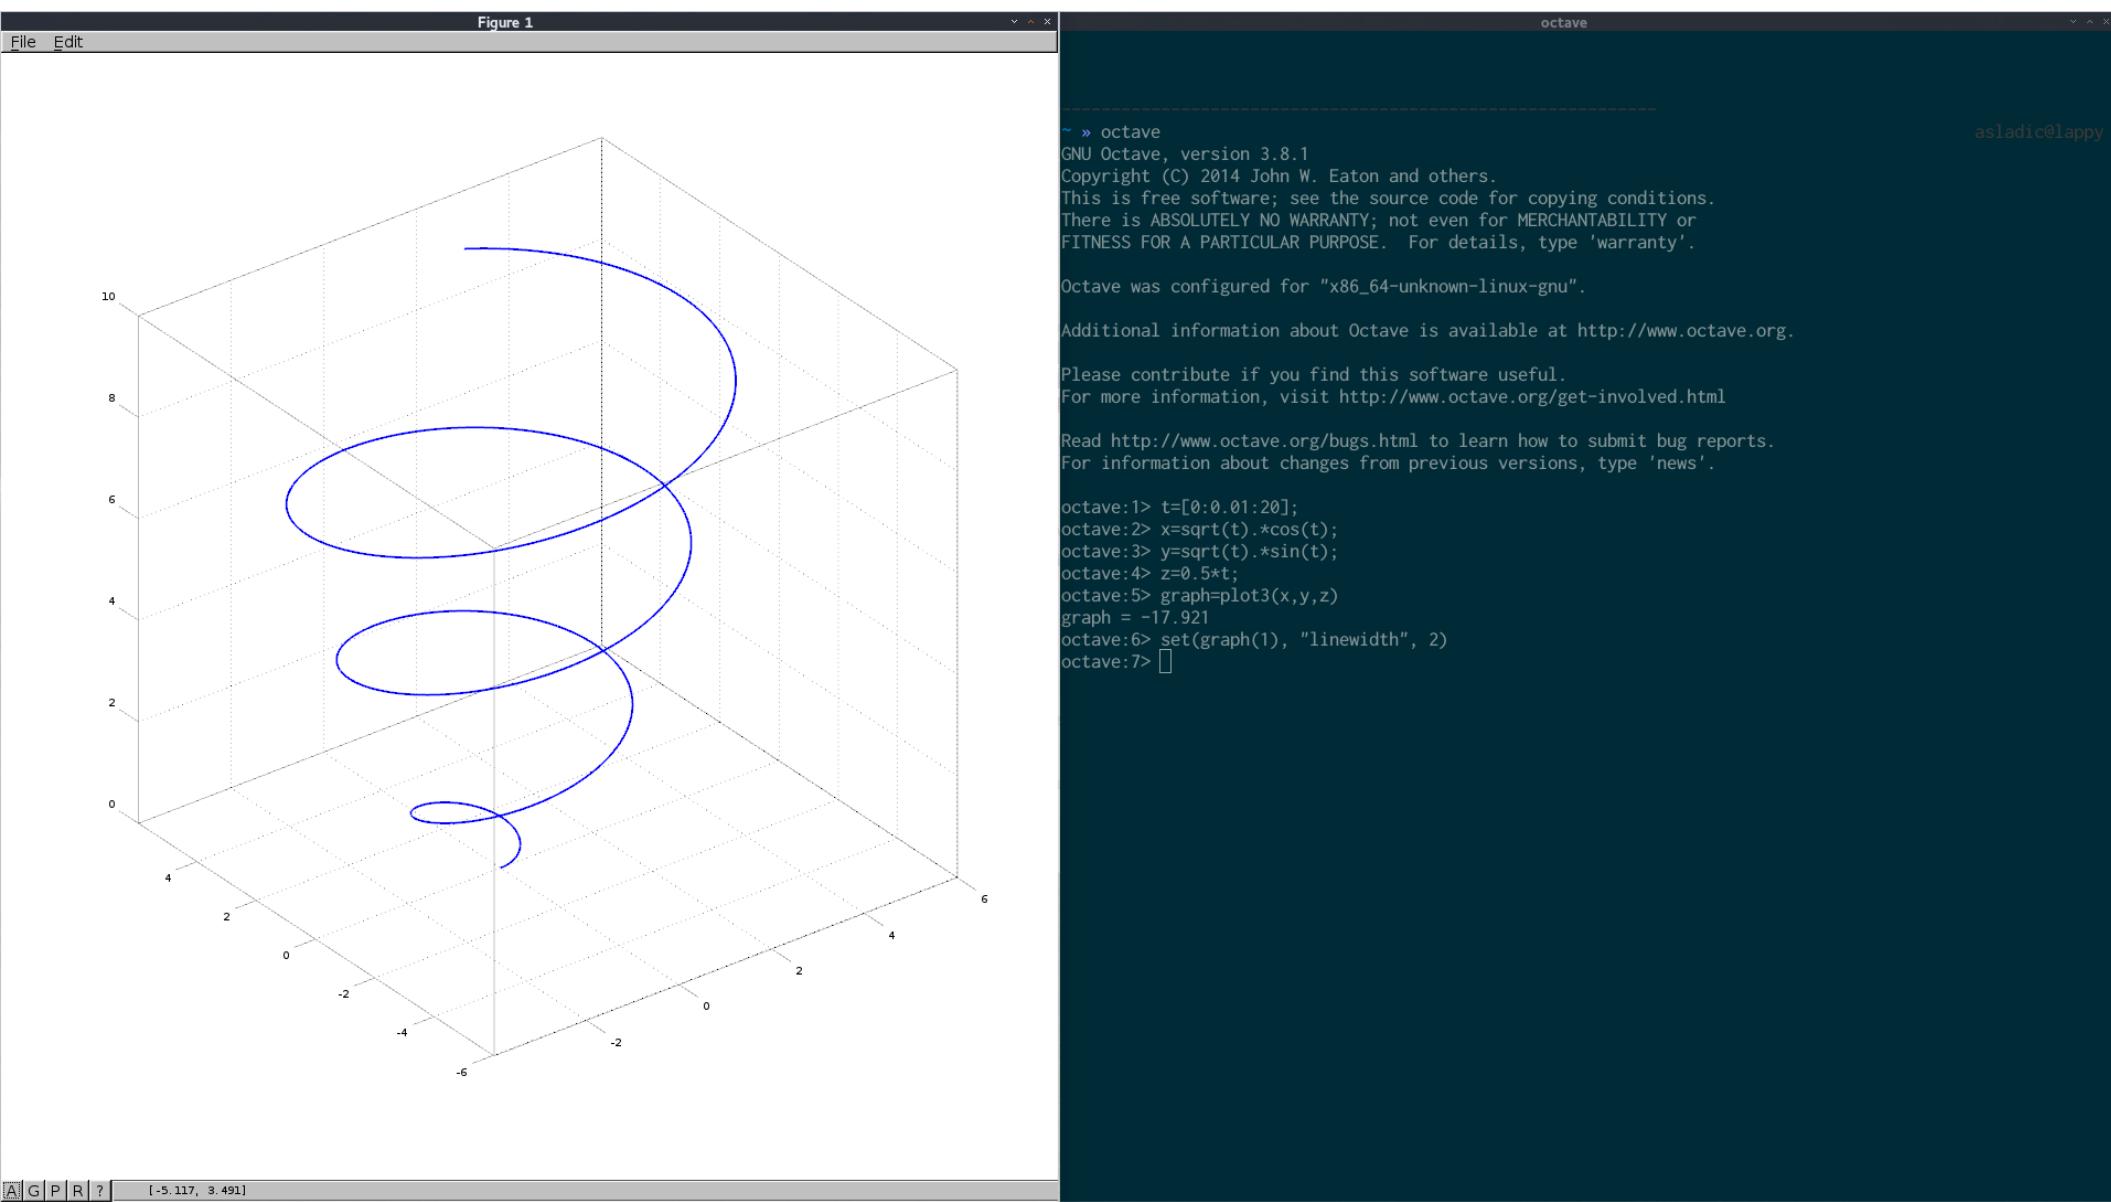
- Wiele dodatkowych (płatnych) bibliotek dla specjalistów
 - Symbolic math
 - Image processing
 - Financial toolbox
 - Bioinformatics
 - Optimization
 - SimBiology



Alternatywy openSource

- GNU Octave (rozpoczęty w 1988, wydania od 1992, rozwijany przez John'a W. Eatona, chemika z University of Wisconsin-Madison)
 - W zasadzie kompatybilny z Matlab'em
 - John W. Eaton Inc. - consulting
- Scipy stack – zestaw bibliotek python'a do obliczeń naukowych
 - Wiele bibliotek, rozwijanych przez niezależne grupy
 - System pakietów, edytor i dystrybucja organizowana przez firmę Enthought, również komercyjne dystrybucje i konsulting
 - Wiele konferencji tematycznych dla naukowców I pracowników przemysłu - także źródło dochodu

Interfejs Octave



Interfejs Enthought Canopy

The screenshot displays the Enthought Canopy software environment across three main windows:

- Editor - Canopy**: This window shows a Python code editor with syntax highlighting. The code includes imports for matplotlib and mayavi, and demonstrates the creation of a 3D surface plot. The interface also features a "Recent files" sidebar and a terminal-like history at the bottom.
- Documentation Browser**: This window provides access to the Canopy User Guide and Online Help. It includes a "DOCUMENTATION" section with a book icon and links to various Python libraries and tools like NumPy, SciPy, and Matplotlib. A "Tips" section offers advice on navigating Sphinx documentation and running code.
- Mayavi Scene 1**: This window displays a 3D visualization of a complex, multi-colored surface plot, likely generated by the Mayavi library shown in the Editor window.

S-Plus dla statystyków

- Język S zaprojektowany w laboratoriach Bell Labs przez Johna Chambers'a
- Implementacja przez R. Douglas'a Martina, profesora statystyki w Seattle
- Wydany komercyjnie w 1988 jako S-Plus, potem kolejno "przejmowany" przez różne korporacje aż do 2008, kiedy przejęła go firma TIBCO
- Adresowany do statystyków akademickich i przemysłowych
- Ogólny, bez specjalizacji w jakiejś dziedzinie zastosowań

Projekt R – Implementacja OpenSource języka S

- Rozpoczęty ok. 1995 projekt stworzenia darmowej implementacji języka S
- Ross Ithaka (obecnie Genentech) and Robert Gentleman (obecnie Univ. Auckland)
- W tej chwili zarządzany przez “R foundation”
- Wiele firm “wspierających” R
- Zachęcam do obejrzenia slajdów Chambers'a:
www.r-project.org/useR-2006/Slides/Chambers.pdf

Rstudio – interfejs do R'a

The screenshot displays the RStudio interface with the following components:

- Script Editor (Left):** Shows an R script named "diamondPricing.R" containing code to load ggplot2, source a plotting function, view and summary the diamonds dataset, calculate average size, and create a qplot of Price vs Carat by Clarity.
- Workspace Browser (Top Right):** Shows the diamonds dataset has 53940 observations and 10 variables. It also lists the calculated aveSize, the clarity levels, and the ggplot object p.
- Console (Bottom Left):** Displays the results of the R commands run in the script, including the summary statistics for the diamonds dataset and the resulting qplot.
- Plots (Bottom Right):** A scatter plot titled "Diamond Pricing" showing Price on the Y-axis (0 to 18000) versus Carat on the X-axis (0.0 to 3.5). The data points are colored by Clarity, with a legend on the right mapping colors to clarity levels: I1 (red), SI2 (orange), SI1 (yellow-green), VS2 (green), VS1 (light green), VVS2 (blue), VVS1 (purple), and IF (pink).

System pakietów w R

- Istotna jest możliwość rozwijania własnych “pakietów” w R (coś na kształt “toolbox’ów” Matlab'a)
- Jest to proces całkowicie demokratyczny, każdy może wysłać pakiet i umieścić go w repozytorium CRAN (Comprehensive R Archive Network)
- Możliwość automatycznej instalacji pakietów z CRAN
- Pewne standardy dokumentacji (winiety) zgodne z “literate programming”

Bioconductor

- Dystrybucja wybranych pakietów R do analizy danych biomedycznych
- Nacisk na łatwiejszą instalację i lepszą dokumentację pakietów
- Stabilny cykl wydań (2 razy do roku)
- Szkolenia adresowane do biologów i medyków
- Kompletnie not-for-profit
- Finansowany z grantów (ok 7-8 osób core team)

Obliczenia symboliczne - Mathematica

- Opracowana w latach 1980'tych przez Stephen'a Wolframa
- Jeden z pierwszych w historii pakietów umożliwiających obliczenia symboliczne
- Bardzo popularna wśród studentów amerykańskich, którzy muszą "zaliczyć" rachunek różniczkowy
- Obecnie także w wersji online: Wolfram Alpha
- Konkurencyjne pakiety: Maple, Mathcad

Mathematica - interfejs

Two Mathematica notebooks are shown side-by-side:

Left Notebook:

```

File Edit Cell Format Input
/u/u2/pfrauenf/mathematica/AnalysisII-Sperb-SS01/U9.nb
Help Browser
Help
File Edit Cell Format Input Kernel Find Window
Help
BesselJ[n, z] gives the Bessel function of the first kind  $J_n(z)$ .
 $J_n(z)$  satisfies the differential equation  $z^2 y'' + z y' + (z^2 - n^2) y = 0$ .
BesselJ[n, z] has a branch cut discontinuity in the complex z plane running from  $-\infty$  to 0.

Plot[{BesselJ[0, x], BesselJ[1, x], BesselJ[2, x], BesselJ[9, x]}, {x, 0, 20},
PlotStyle -> {RGBColor[1, 0, 0], RGBColor[0, 1, 0], RGBColor[0, 0, 1],
RGBColor[1, 0, 1]}]

```

Right Notebook:

```

File Edit Cell Format Input Kernel Find Window
Help
Help Browser
Help
File Edit Cell Format Input Kernel Find Window
Help
of a surface representing an array of height values.
element of the surface shaded according to the specification in

```

Help Browser:

- Plot3D
- ListPlot3D**
- ParametricPlot3D

Text:

of a surface representing an array of height values.
element of the surface shaded according to the specification in

Code:

```

In[1]:= ListPlot3D[Table[Sin[x y] + Random[Real, {-0.15, 0.15}], {x, 0, 3 Pi / 2, Pi / 15}, {y, 0, 3 Pi / 2, Pi / 15}]];

```

Obliczenia symboliczne Open Source

- Maxima (1992-), a wcześniej Macsyma (1968-1982)
- Wydana w 1998 na licencji GPL
- Napisana w języku lisp
- Wiele konkurencyjnych interfejsów (WXMaxima, Gmaxima itp)
- Maxima skupiona na obliczeniach symbolicznych, bez większej funkcjonalności w numeryce

SAGE math cloud

(dawniej sage notebook)

- Stosunkowo nowy projekt (inny niż sage synapse)
- Połączenie wielu środowisk obliczeniowych
 - Python (Numpy, Scipy, Sympy, matplotlib, Networkx)
 - Maxima
 - R
 - GAP, FLINT, GD, JMOL, PALP, Singular
- Środowisko w przeglądarce, sesja na serwerze lub “w chmurze”

Interfejs SAGE

Use Sage to Solve Equations

last edited on April 11, 2011 05:45 PM by admin

File... Action... Data... sage Typeset

Print Worksheet Edit Text Undo Share Publish

```
var('a b c d e f x y')
```

```
(a, b, c, d, e, f, x, y)
```

```
show(solve(a*x^2 + b*x + c == 0, x)[0])
```

$$x = -\frac{b + \sqrt{-4ac + b^2}}{2a}$$

```
show(solve(x^3 + a*x + b == 0, x)[0])
```

$$x = \frac{(-i\sqrt{3} + 1)a}{6 \left(\frac{1}{18}\sqrt{4a^3 + 27b^2}\sqrt{3} - \frac{1}{2}b\right)^{\left(\frac{1}{3}\right)}} - \frac{1}{2} \left(i\sqrt{3} + 1\right) \left(\frac{1}{18}\sqrt{4a^3 + 27b^2}\sqrt{3} - \frac{1}{2}b\right)^{\left(\frac{1}{3}\right)}$$

```
solve([a*x + b*y == c, d*x + e*y == f], x, y)
```

```
[[x == -(b*f - c*e)/(a*e - b*d), y == (a*f - c*d)/(a*e - b*d)]]
```

[evaluate](#)

Excel?

- Najpopularniejszy pakiet do obliczeń
- Bardzo prosty interfejs
- Często stosowany również w bio-informatyce
- Ma spore ograniczenia (np. Maksymalna liczba linii w arkuszu), które utrudniają rozwój projektów prowadzonych w arkuszu
- Brak możliwości efektywnego testowania,
- brak debuggerów