

Obliczenia Naukowe

Wykład 12 - Pakiety do obliczeń:
naukowych i inżynierskich
Przegląd i porównanie

Bartek Wilczyński

21.5.2020

Plan na dziś

- Pakiety do obliczeń: przegląd zastosowań
- różnice w zapotrzebowaniu: naukowcy, inżynierowie, statystycy/medycy
- Matlab/octave/scipy – obliczenia numeryczne
- Mathematica/Maxima/Sympy – obliczenia symboliczne
- Sage i SageCloud – zintegrowany pakiet opensource
- 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

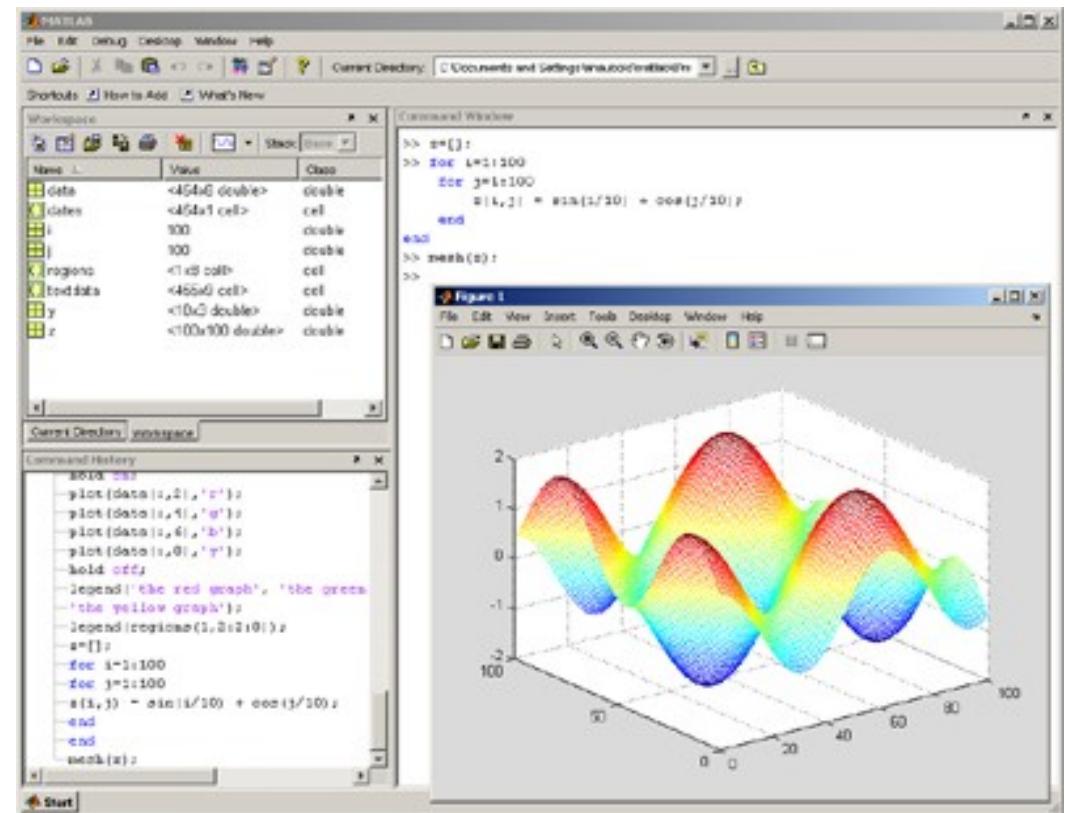
- Komputer jako “potężniejszy kalkulator”
- W zasadzie wszystko można zaprogramować samemu, ale każdemu mogą się przydać:
 - Interfejs użytkownika łatwiejszy niż typowego kompilatora
 - Możliwość zaawansowanej grafiki
 - Dobrze przetestowane standardowe procedury
 - Interfejsy do urządzeń
 - Wsparcie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

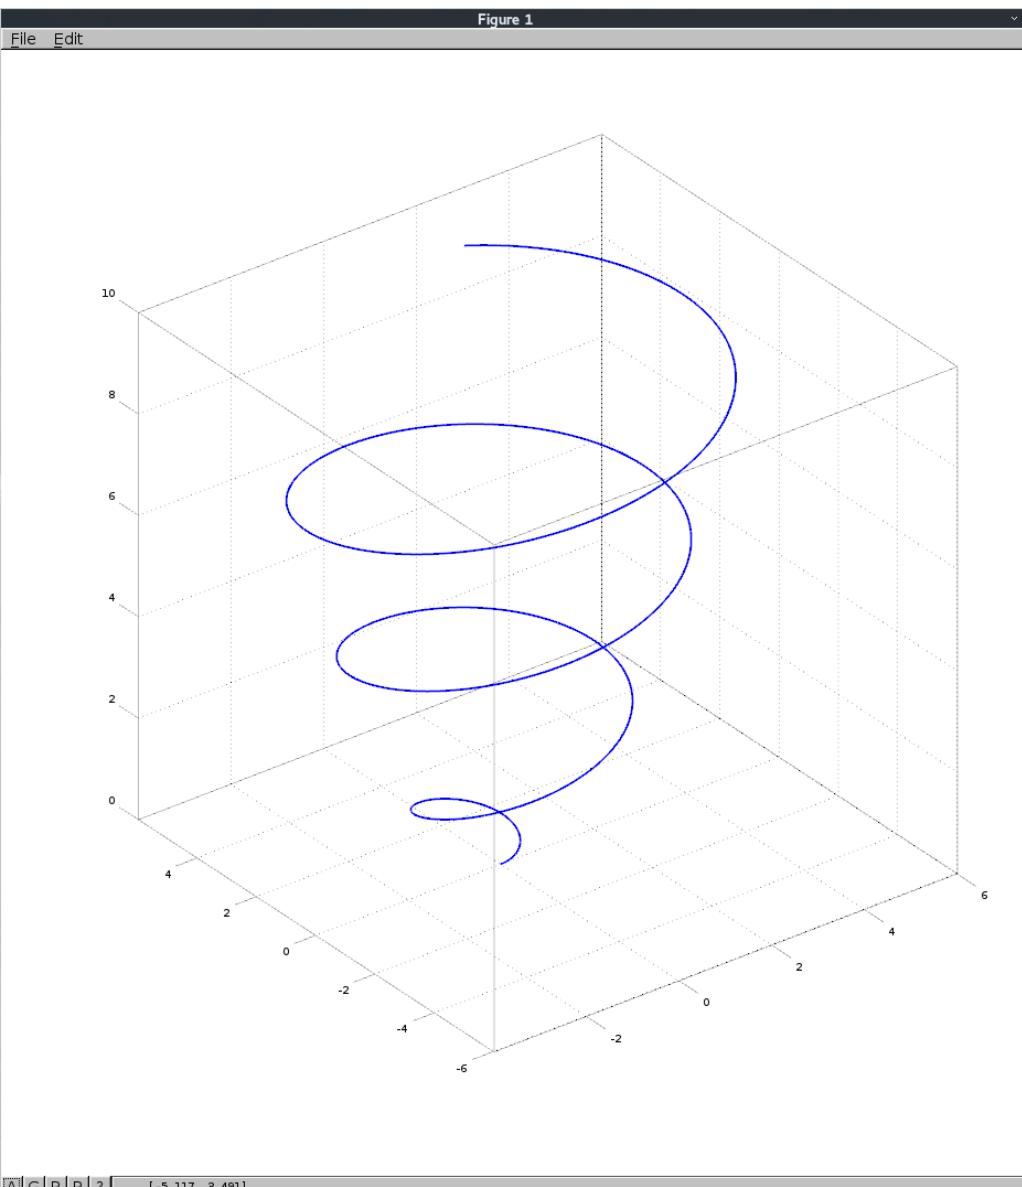
- Wiele dodatkowych (płatnych) bibliotek dla specjalistów
 - Symbolic math
 - Image processing
 - Financial toolbox
 - Bioinformatics
 - Optimization
 - SimBiology



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



```
octave
GNU Octave, version 3.8.1
Copyright (C) 2014 John W. Eaton and others.
This is free software; see the source code for copying conditions.
There is ABSOLUTELY NO WARRANTY; not even for MERCHANTABILITY or
FITNESS FOR A PARTICULAR PURPOSE. For details, type 'warranty'.

Octave was configured for "x86_64-unknown-linux-gnu".

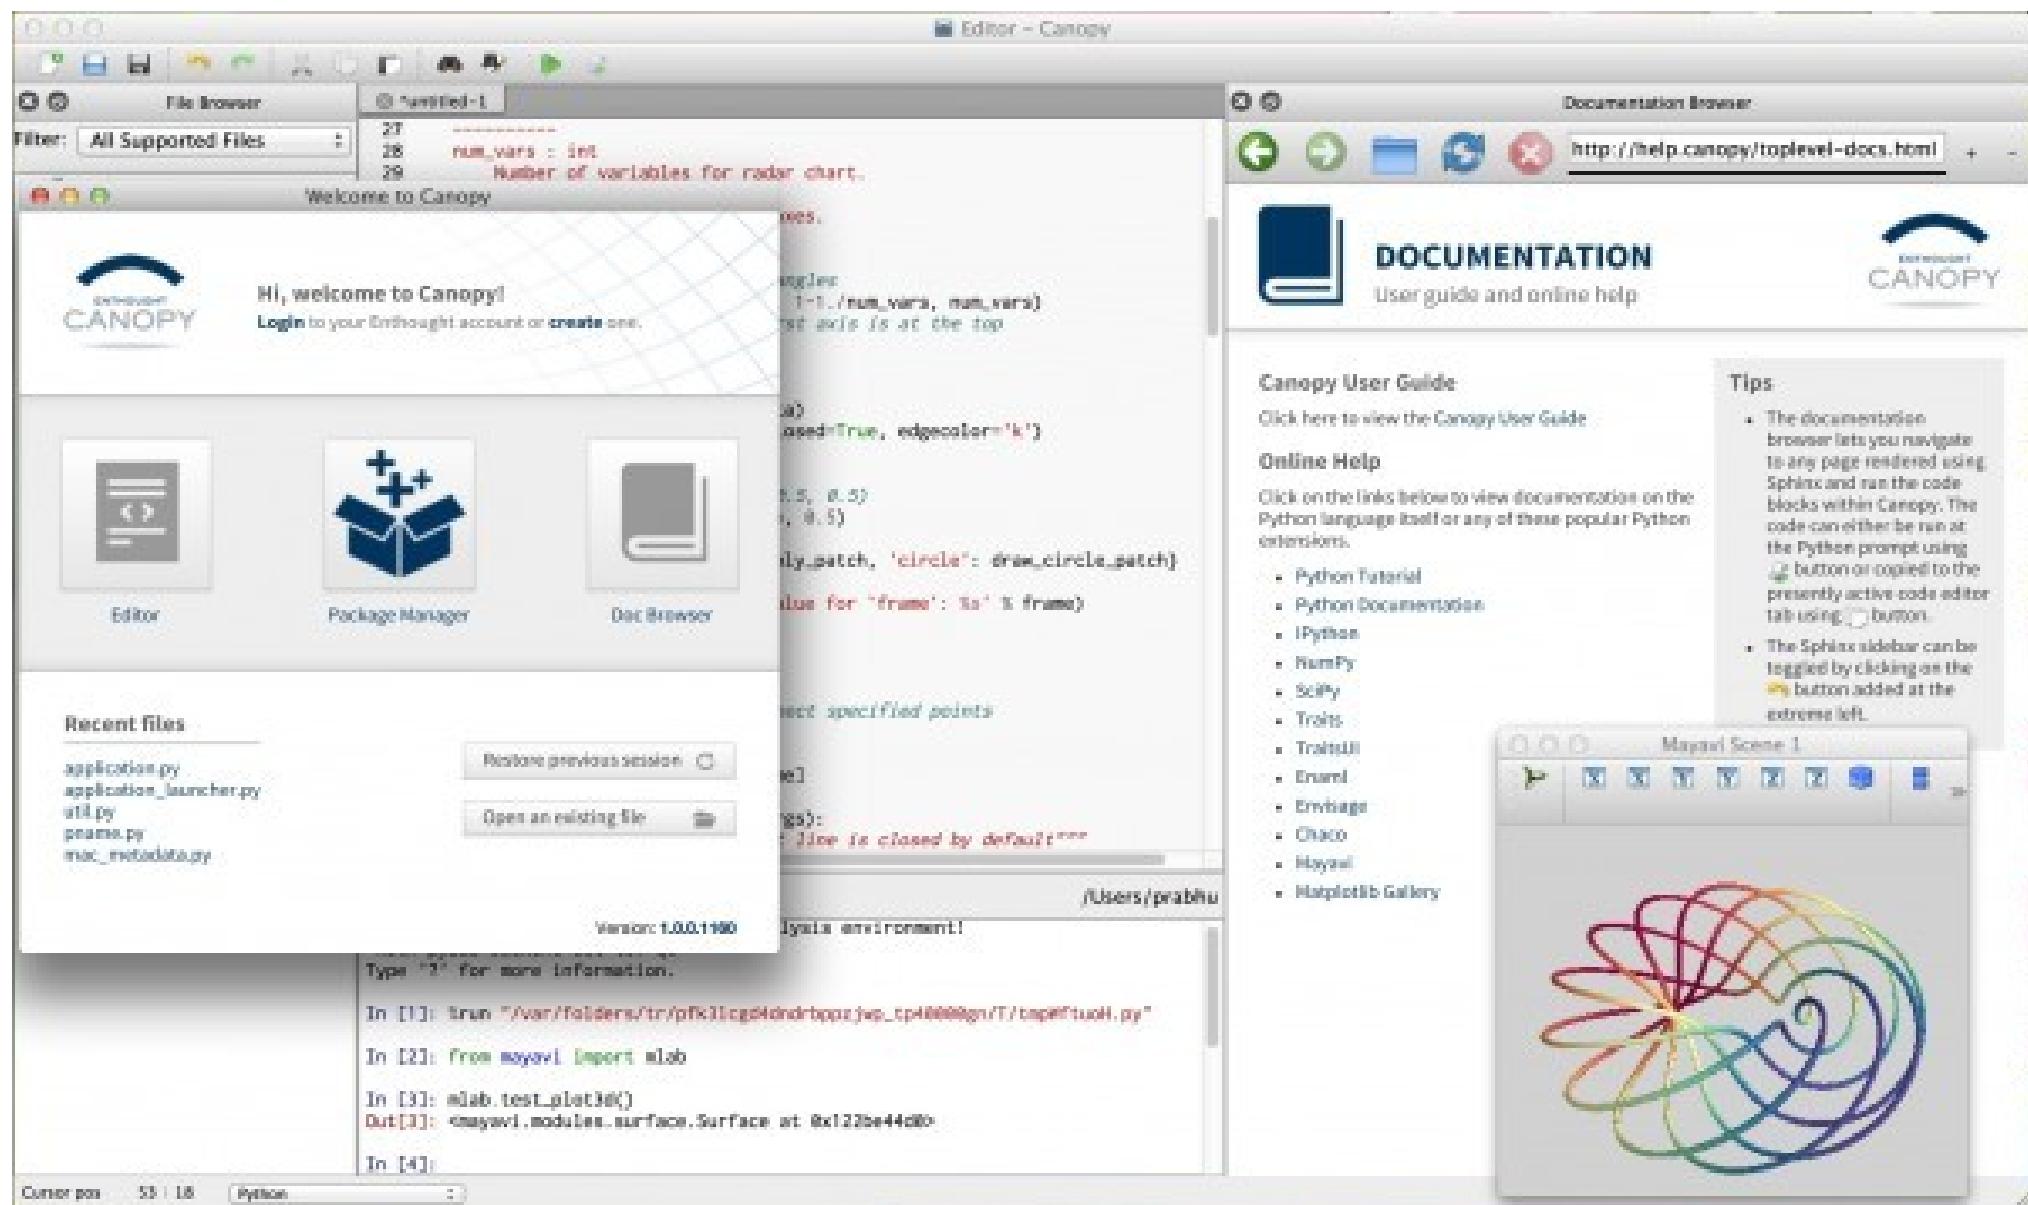
Additional information about Octave is available at http://www.octave.org.

Please contribute if you find this software useful.
For more information, visit http://www.octave.org/get-involved.html

Read http://www.octave.org/bugs.html to learn how to submit bug reports.
For information about changes from previous versions, type 'news'.
```

```
octave:1> t=[0:0.01:20];
octave:2> x=sqrt(t).*cos(t);
octave:3> y=sqrt(t).*sin(t);
octave:4> z=0.5*t;
octave:5> graph=plot3(x,y,z)
graph = -17.921
octave:6> set(graph(1), "linewidth", 2)
octave:7>
```

Interfejs Enthought Canopy



Obliczenia symboliczne – Mathematica i podobne

- 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, Symbolic math toolbox w matlabie (dawny muPAD)

Mathematica - interfejs

Two Mathematica notebooks are shown side-by-side:

Left Notebook (hexaeder.nb):

```

aa = Table[A[[i, j]], {i, 0, 1}, {j, 0, 1}]; aa
bb = Table[B[[i, j]], {i, 0, 1}, {j, 0, 1}]; bb
ll = Table[L[[i]], {i, 0, 1}]; ll
mm = Table[M[[i]], {i, 0, 1}]; mm
ss = LinearSolve[aa, 1 + ll + mm][[3]] / (aa + bb)
ss

```

Right Notebook (AnalysisII-Sperb-SS01/U9.nb):

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]}]

```

- Graphics -

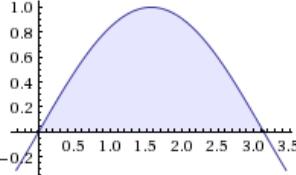
In[1]:= ListPlot3D[Table[Sin[x y] + Random[Real, {-0.15, 0.15}], {x, 0, 3 Pi/2, Pi/15}, {y, 0, 3 Pi/2, Pi/15}]];

Wolfram Alpha – mathematica online

 **WolframAlpha** computational... knowledge engine

integrate sin x dx from x=0 to pi

Definite integral:
 $\int_0^\pi \sin(x) dx = 2$

Visual representation of the integral:


Riemann sums:
left sum $\frac{\pi \cot(\frac{\pi}{2n})}{n} = 2 - \frac{\pi^2}{6n^2} + O\left(\left(\frac{1}{n}\right)^4\right)$

(assuming subintervals of equal length)

Indefinite integral:
 $\int \sin(x) dx = -\cos(x) + \text{constant}$

Related Queries:

- = [y\(x\) - 3 \(integrate y\(z\) sin\(x+z\) from z = 0 ...\)](#)
- = [area between sinx and cosx from x = 0 t...](#)
- = [integrate using midpoint method sin\(x\) fr...](#)
- = [area under y = sin\(x\) from x = 0 to pi](#)
- = [integrate 1/sin\(x\) dx](#)

- Interfejs online umożliwiający korzystanie z wielu narzędzi do obliczeń symbolicznych
- Duża część funkcjonalności darmowa, ale wiele funkcji (np. rozpiswanie rozwiązania na kroki) - płatna

Obliczenia numeryczne a symboliczne

- W obliczeniach symbolicznych próbujemy obejść problem numerycznych zaokrągleń i przybliżeń poprzez opis równań algebraicznych explicite
- Tego typu pakiety pozwalają na dokładne odwzorowanie równań, jednak cierpią z powodu heurystycznych metod rozwiązania
- Proste operacje w takich pakietach są prostsze niż “na kartce” ale trudne często mogą natrafić na więcej problemów niż korzyści
- Na pewno są skuteczne do sprawdzania, czy nie pomyliliśmy się w obliczeniach

Typowe funkcje pakietów symbolicznych

- Przekształcanie, upraszczanie wzorów
- Rozwiązywanie równań i układów równań algebraicznych
- Znajdowanie granic wyrażeń i ciągów liczbowych
- Całkowanie i różniczkowanie symboliczne
- Wykresy
- Ładne formatowanie wzorów matematycznych (często przy użyciu LaTeX'a)

Maxima - 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)
- Skupiona na obliczeniach symbolicznych

Projekt SymPy

- Projekt narzędzi do obliczeń symbolicznych dla języka python
- Powstaje od ok. 2005 roku, obecnie osiągnął wersję 1.0
- Napisany w pythonie, kładzie nacisk na czytelność kodu i rozszerzalność, niekoniecznie na szybkość i pełność systemu
- Zawiera podstawowe funkcjonalności (zmienne symboliczne, granice, równania, różniczkowanie, całkowanie symboliczne)
- Dobrze integruje się z innymi pakietami w pythonie

Przykład użycia sympy

ture | <https://notch.mimuw.edu.pl:8888/notebooks/Symbolicznie.ipynb>

jupyter Symbolicznie Last Checkpoint: a few seconds ago (autosaved) Logout

File Edit View Insert Cell Kernel Help Python 2

In [37]: `import sympy,math
print math.sqrt(8),sympy.sqrt(8)
print math.sqrt(8)**2, sympy.sqrt(8)**2
sympy.Rational(1,3),1./3`

2.82842712475 2*sqrt(2)
8.0 8

Out[37]: (1/3, 0.3333333333333333)

In [26]: `from sympy import symbols
x, y = symbols('x y')
expr = x + 2*y # wyrażenia symboliczne
print expr
print expr - x**2`

x + 2*y
-x**2 + x + 2*y

In [30]: `from sympy import expand, factor #wymnażanie
expanded_expr = expand(x*expr)
print x*expr, expanded_expr`

x*(x + 2*y) x**2 + 2*x*y

In [31]: `factor(expanded_expr) # grupowanie`

Out[31]: x*(x + 2*y)

In [19]: `sympy.diff(sin(x)*exp(x), x) # różniczkowanie`

Out[19]: exp(x)*sin(x) + exp(x)*cos(x)

In [34]: `sympy.integrate(exp(x)*sin(x) + exp(x)*cos(x), x) # całkowanie`

Out[34]: exp(x)*sin(x)

In [35]: `sympy.limit(sin(x)/x, x, 0) # granice`

Out[35]: 1

In [22]: `from sympy import latex
latex(Integral(cos(x)**2, (x, 0, pi))) # wypisywanie w LaTeX'u`

Out[22]: '\int_0^{\pi} \cos^2(x) dx'

SAGE notebook

- Stosunkowo nowy projekt
- 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

 The Sage Notebook
Version 4.6.1

admin [Toggle](#) | [Home](#) | [Published](#) | [Log](#) | [Settings](#) | [Help](#) | [Report a Problem](#) | [Sign out](#)

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](#)

aaa - SageMathCloud - Mozilla Firefox

aaa - SageMathCloud

https://cloud.sagemath.com/projects/bc74...

Search

Bartek Wilczynski About 133ms

Projects aaa

Files + New Log Find Settings 2016-05-30-002158.sagews

Modes Help # Data Control Program

x Plots Calculus Linear Graphs Number Theory Rings

%sage

```
1
2
3 integrate(1 + x + x^2, x)
4 1/3*x^3 + 1/2*x^2 + x
5
6
7 show(integrate(1 + x + x^2, x))
8 %var x, theta
9
10
11 solve(x**2-1,x)
12
13 [x == -1, x == 1]
14
15
16 plot(x**2-1)
```

17

Jupyter notebook

Screenshot of the Jupyter website showing the interface and features:

The screenshot shows the Jupyter homepage with the following elements:

- Header:** Project Jupyter | HC x Bartek
- Address bar:** jupyter.org
- Logo:** jupyter
- Navigation menu:** Install, About, Resources, Documentation, NBViewer, Widgets, Blog, Donate
- Content area:**
 - Left sidebar:** Shows the Jupyter Notebook interface with a code cell containing the Lorenz equations and a resulting 3D plot of the Lorenz attractor.
 - Right sidebar:** Text about the Lorenz system, followed by a code cell with parameters and a resulting 2D plot of the Lorenz attractor.
 - Bottom section:** Four cards describing Jupyter's features:
 - Language of choice:** The Notebook has support for over 40 programming languages, including those popular in Data Science such as Python, R, Julia and Scala.
 - Share notebooks:** Notebooks can be shared with others using email, Dropbox, GitHub and the Jupyter Notebook Viewer.
 - Interactive widgets:** Code can produce rich output such as images, videos, LaTeX, and JavaScript. Interactive widgets can be used to manipulate and visualize data in realtime.
 - Big data integration:** Leverage big data tools, such as Apache Spark, from Python, R and Scala. Explore that same data with pandas, scikit-learn, ggplot2, dplyr, etc.

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
- Ma wiele funkcji, które warto znać, zwłaszcza, że często dane do obróbki dostajemy właśnie w Excel'u

COMMENT

Open Access



Gene name errors are widespread in the scientific literature

Mark Ziemann¹, Yotam Eren^{1,2} and Assam El-Osta^{1,3*}

Abstract

The spreadsheet software Microsoft Excel, when used with default settings, is known to convert gene names to dates and floating-point numbers. A programmatic scan of leading genomics journals reveals that approximately one-fifth of papers with supplementary Excel gene lists contain erroneous gene name conversions.

Keywords: Microsoft Excel, Gene symbol, Supplementary data

Abbreviations: GEO, Gene Expression Omnibus; JIF, journal impact factor

The problem of Excel software (Microsoft Corp., Redmond, WA, USA) inadvertently converting gene symbols to dates and floating-point numbers was originally described in 2004 [1]. For example, gene symbols such as *SEPT2* (Septin 2) and *MARCH1* [Membrane-Associated Ring Finger (C3HC4) 1, E3 Ubiquitin Protein Ligase] are converted by default to '2-Sep' and '1-Mar', respectively. Furthermore, RIKEN identifiers were described to be automatically converted to floating point numbers (i.e. from accession '2310009E13' to '2.31E+13'). Since that report, we have uncovered further instances where

frequently reused. Our aim here is to raise awareness of the problem.

We downloaded and screened supplementary files from 18 journals published between 2005 and 2015 using a suite of shell scripts. Excel files (.xls and.xlsx suffixes) were converted to tabular separated files (tsv) with ssconvert (v1.12.9). Each sheet within the Excel file was converted to a separate tsv file. Each column of data in the tsv file was screened for the presence of gene symbols. If the first 20 rows of a column contained five or more gene symbols, then it was suspected to be a list of gene symbols, and then a regular expression (regex) search of the entire column was applied to identify gene symbol errors. Official gene symbols from Ensembl version 82, accessed November 2015, were obtained for *Arabidopsis thaliana*, *Caenorhabditis elegans*, *Drosophila melanogaster*, *Danio rerio*, *Escherichia coli*, *Gallus gallus*, *Homo sapiens*, *Mus musculus*, *Oryza sativa* and *Saccharomyces cerevisiae* [2]. The regex search used was similar to that described previously by Zeeberg and colleagues [1], with the added screen for dates in other formats (e.g. DD/MM/YY and MM-DD-YY). To expedite analysis of supplementary files from multi-disciplinary journals, we limited the articles screened to those that have the keyword 'genome' in the title or abstract (*Science*, *Nature* and *PLoS One*). Excel files (.xls and.xlsx) deposited in NCBI Gene Expression Omnibus (GEO) [3] were also

Table 1 Results of the systematic screen of supplementary Excel files for gene name conversion errors

Journal ^a	Number of Excel files screened	Number of gene lists found	Number of papers with gene lists	Number of supplementary files affected	Number of papers affected	Number of gene names converted
<i>PLoS One</i>	7783	2202	994	220	170	4240
<i>BMC Genomics</i>	11464	1650	801	218	158	4932
<i>Genome Res</i>	2607	580	251	114	68	3180
<i>Nucleic Acids Res</i>	2117	540	315	88	67	1661
<i>Genome Biol</i>	2678	664	257	97	63	1878
<i>Genes Dev</i>	932	395	190	75	55	1593
<i>Hum Mol Genet</i>	980	372	168	48	27	1724
<i>Nature</i>	482	150	74	27	23	1375
<i>BMC Bioinformatics</i>	1790	235	152	26	21	534
<i>RNA</i>	569	127	77	20	15	1341
<i>Nat Genet</i>	264	70	37	12	9	178
<i>Bioinformatics</i>	731	112	67	11	6	339
<i>PLoS Comput Biol</i>	177	79	32	6	6	46
<i>PLoS Biol</i>	143	54	29	7	5	206
<i>Mol Biol Evol</i>	995	112	79	7	4	56
<i>Science</i>	172	36	19	7	3	451
<i>Genome Biol Evol</i>	490	32	25	2	2	121
<i>DNA Res</i>	801	57	30	2	2	6
<i>Total</i>	35175	7467	3597	987	704	23861

^aThe 18 journals investigated are ordered by the number of papers affected by gene name conversion errors