

Data Science

Herramientas, lenguajes y Python

Gonzalo Rios




MA6201 - Computación Científica
Grupo de Aprendizaje de Máquinas, infErencia y Señales
Centro de Modelamiento Matemático
Universidad de Chile

Agosto 2017

Data Science

¿Qué es Data Science?

Data Science es un campo interdisciplinario que aplica técnicas **matemáticas, estadísticas y computacionales** a diversas áreas: **biología, física, economía, sicología, sociología**, entre otras.




Copyright © 2014 by Steven Geringer Raleigh, NC.
Permission is granted to use, distribute, or modify this image,
provided that this copyright notice remains intact.

Data Science

¿Qué hace Data Science?

Data Science tiene la misión de **modelar**, **analizar**, **entender**, **visualizar** y **extraer** conocimiento a partir de **datos**




Data Scientists son los profesionales de **Data Science**, que necesitan conocer más **estadística** que un ingeniero de software, y saber más **ingeniería de software** que un estadístico

The image is a screenshot of the Harvard Business Review website. On the left is a sidebar with navigation links: 'THE LATEST', 'MOST POPULAR', 'ALL TOPICS', 'VIDEO', 'MAGAZINE ARCHIVE', 'STORE', 'VISUAL LIBRARY', and 'MY LIBRARY'. The main content area features the article title 'Data Scientist: The Sexiest Job of the 21st Century' in large black font, with the authors 'by Thomas H. Davenport and D.J. Patil' and 'FROM THE OCTOBER 2012 ISSUE' below it. A horizontal bar with various icons (summary, save, share, comment, text size, print, buy copies) is positioned below the article information. The article text begins with a large 'W' and the sentence 'hen Jonathan Goldman arrived for work in June 2006 at LinkedIn, the business networking site, the place still felt like a start-up. The company had just under 8 million accounts, and the number was growing quickly as'.

Data Scientist

Valorados en la Industria Privada

Google, Microsoft y Facebook contratan Data Scientists




Ref: <https://www.glassdoor.com>

Data Scientists

Habilidades por Roles

Existen diferentes roles relacionados con **Data Science**




Source: A.T. Kearney analysis

Data Scientists

Habilidades Interdisciplinarias


Un **Data Scientist** posee conocimientos (y **creatividad!**) en **modelación, visualización, bases de datos y programación**



Machine Learning

Algoritmos que Aprenden


Machine Learning es un área cuyo objetivo es desarrollar **algoritmos** que permitan a las **computadoras aprender**.



Machine Learning

Formas de Aprender

Una buena forma de aprender **Machine Learning** es haciendo un **curso online**, leer un **libro** y asistir a **charlas**



Pronto empezarán los **Martes de Máquina!**

<http://www.coursera.org/>

<http://mitpress.mit.edu/books/>

<http://games.cmm.uchile.cl/>

¿Cuál lenguaje de programación escoger?


Data Science necesita el uso de un **lenguaje de programación**,
el problema es como **escoger** uno entre cientos (o miles)!



Programming Languages


Historia: 1837 - 1979

En 1837, **Charles Babbage** diseñó la primera **máquina programable**, y fue **Ada Lovelace** quien publicó en 1843 el primer **programa**. En 1946 se construyó **ENIAC**, el primer computador Turing-completo programable de propósitos generales.




Programming Languages

Historia: 1980 - Hoy



Paradigmas de Programación


Los **paradigmas de programación** son las diferentes corrientes filosóficas de programación según la **abstracción de elementos**.



Programming Languages

Stack Overflow Ranking vs GitHub Ranking

Documentación y librerías acelera los tiempos de desarrollo




Ref: <http://redmonk.com/>

Programming Languages

Top 10 IEEE Spectrum Ranking - Google Search Evolution

Los lenguajes **populares** tienden a ser más **robustos**, pero las **tendencias** van cambiando a lo largo del tiempo.




Ref: <http://spectrum.ieee.org> 2016 - <http://www.udacity.com/>

Programming Languages

Eficiencia Computacional

Un lenguaje más **eficiente** computacionalmente permite resolver problemas de mayor **complejidad**, tema fundamental en **big data**




Ref: <http://julialang.org/>

Programming Languages

Velocidad de Ejecución vs Velocidad de Desarrollo

Al momento de programar, es importante **equilibrar** la velocidad de **ejecución** con la velocidad de **programación**.



Programming Languages

Librerías para Big Data

Para poder abarcar problemas de **Big Data**, es necesario poder contar con **librerías** especialmente diseñadas para gestionar grandes **volúmenes** de datos y obtener una gran **velocidad** de cálculos en **complejas** estructuras de datos.




Programming Languages

Disponibilidad de librerías

- **Apache Spark:** procesamiento de datos a gran escala
Python, Java, R
- **Apache Mesos:** manejo de recursos computacionales
Python, Java, C/C++
- **Open MPI:** computación paralela de alto desempeño
Python, Java, C/C++, R, Fortran, Matlab
- **nVidia CUDA:** programación en GPUs
Python, Java, C/C++, R Fortran
- **TensorFlow:** modelos de machine deep learning
Python, C/C++

Programming Languages

Python



- Monty Python (1969)
- Guido van Rossum (1991)
- Python Software Foundation (2001)
- Python 2.7.13 (2016) / 3.6.2 (2017)



Ref: <http://www.python.org>

Python reúne las características necesarias para **Data Science**, además de ser un buen lenguaje de programación para **uso general**



Ref: <https://www.python.org/dev/peps/pep-0020/>

Python cuenta con diversas implementaciones, distribuciones, herramientas y gestores de paquetes.

- **Pip:** Python Package Index.
- **Anaconda:** Python distribution/installer.
- **Conda:** Binary Package Manager.
- **Jupyter:** Web-Based Interactive Notebook.
- **Django:** Framework Web.
- **CPython:** C bytecode interpreter.
- **Jython:** Java bytecode interpreter.
- **IronPython:** .NET bytecode interpreter.
- **PyPy:** Just-in-time compiler (RPython to machine code).
- **MicroPython:** Microcontroller compiler.

Python es capaz de ejecutar código de otros lenguajes de uso general como **C**, **Fortran** y **Java**, además de ser una alternativa completa a **lenguajes científicos** de uso específico

- **Cython**: ejecutar código C
- **F2py**: ejecutar código Fortran
- **Jep**: integrar con Java
- **Rpy2**: integrar con R
- **Numpy/Scipy**: alternativa Matlab
- **Sympy/SageMath**: alternativa a Mathematica

Python dispone de un rico ecosistema compuesto de **librerías open-source** para **matemáticas, estadística, machine learning** y ciencia en general.



NumPy
Base N-dimensional
array package



SciPy library
Fundamental library
for scientific
computing



Matplotlib
Comprehensive 2D
Plotting



IPython
Enhanced
Interactive Console



Sympy
Symbolic
mathematics



pandas
Data structures &
analysis

Ref: <http://www.scipy.org>

Una forma muy simple de aprender **Python** es hacer un curso online, recomiendo revisar **www.sololearn.com**. En las próximas sesiones del ramo aprenderemos:

- **Programación**: Ecosistema, sintaxis, librerías, paradigmas.
- **Manipulación**: Numpy, Pandas.
- **Visualización** : Matplotlib, Seaborn, Bokeh.
- **Modelación**: Scipy, Scikit-Learn, PyMC3.
- **Eficiencia**: Profiling, Compilation, Multiprocessing.

Gracias!

Los esperamos en las próximas sesiones!



PD: Bienvenido a la Iglesia Pythoneana de los Programadores de los Últimos Códigos