



**UNIVERSITÀ  
DEGLI STUDI  
DI UDINE**  
hic sunt futura

# La Scienza dei Dati

**Eddy Maddalena**

Dipartimento di Matematica, Informatica e Fisica (DMIF), Università di Udine

Liceo Scientifico Bertoni, Udine, 18 aprile 2023

# Eddy Maddalena



## Contatti:

-  [eddy.maddalena@uniud.it](mailto:eddy.maddalena@uniud.it)
-  [eddymaddalena.net](http://eddymaddalena.net)

## Docente:

- **Fondamenti di Scienza dei dati e laboratorio** (triennale)
- **Progettazione e Analsi orientata agli Oggetti** (magistrale)

## Ricercatore:

- Crowdsourcing, Information Retrieval, Human Computation, Gamification, Citizen Science, Smart Cities, ..

# Scaletta

- Presentazioni - 2 minuti
- Panoramica sulla Data Science - 30 minuti
- Panoramica su R ed RStudio - 18 minuti

# I dati


"Un dato è una descrizione elementare codificata di un'informazione, un'entità, di un fenomeno, di una transazione, di un avvenimento o di altro."

Wikipedia

"I dati sono informazione fattuale (come misurazioni o statistiche), usate come base per ragionamenti, discussioni e calcoli"

Joe Martin

# I dati digitali



Bourns



Roomba




Ambient Weather



Instagram



Google Home




Amazon Shop

# Lo Scienziato dei Dati


- Lavora con esperti di dominio
- Background multidisciplinare: statistica, programmazione, data visualization, comunicazione, ..
- Guadagna mediano USA 2022: **\$54k all'anno** [1]
- Stipendio di un Data Scientist USA 2022: **\$123k all'anno** [2]





# Il workflow della Data Science

Il ciclo di vita della Data Science va dall'import dei dati fino alla comunicazione dei risultati



# Import

- Inizialmente si importano i dati in R
- Tipicamente si caricano i dati presenti in un file, un database o delle web API e li si trasforma in un data frame di R

## Esempio di file CSV (Comma-separated values)

```
City, Country, Population, Lat, Lng, Capital  
Udine, Italy, 99341, 46.0693000, 13.2371500, FALSE  
Trento, Italy, 117417, 46.0678700, 11.1210800, FALSE  
Ljubljana, Slovenia, 279631, 46.0510800, 14.5051300, TRUE  
Lugano, Switzerland, 63932, 46.0100800, 8.9600400, FALSE
```

# Tidy

- Una volta importati i dati è buona norma **pulirli e riordinarli**
- Pulire i dati significa immagazzinarli in una forma consistente alla semantica del dataset e al modo in cui questo è immagazzinato
- Pulire ed organizzare i dati è importante. Lavorare su una struttura consistente permette di focalizzarsi sulle proprie domande o ipotesi
  - evitando di sprecare tempo ed energie a riorganizzare continuamente i propri dati

# Tidy: La forma normale

- Un dataframe pulito avrà:
  - una variabile per ogni colonna
  - un'osservazione per ogni riga

	▲ Sepal.Length ◆	▼ <b>VARIABILE</b> Sepal.Width ◆	▼ Petal.Length ◆	▼ Petal.Width ◆	▼ Species ◆	
41	5.0	3.5	1.3	0.3	setosa	
42	4.5	2.3	1.3	0.3	setosa	
43	4.4	3.2	1.3	0.2	setosa	
44	5.0	3.5	1.6	0.6	setosa	
45	5.1	3.8	1.9	0.4	setosa	
46	4.8	3.0	1.4	0.3	setosa	
47	5.1	3.8	1.6	0.2	setosa	
48	4.6	3.2	1.4	0.2	setosa	
49	5.3	3.7	1.5	0.2	setosa	
<b>OSSERVAZIONE</b>	50	5.0	<b>VALORE</b> (3.3)	1.4	0.2	setosa
51	7.0	3.2	4.7	1.4	versicolor	
52	6.4	3.2	4.5	1.5	versicolor	

# Transform





























- Dati puliti e organizzati possono essere **trasformati** (effettuando delle **query**)
- Le trasformazioni includono:
  - Concentrarsi sulle osservazioni di interesse (ad es., tutte le persone di una città; i dati raccolti in un mese specifico in un form)
  - Creare nuove variabili in funzione di variabili esistenti (ad es., calcolare la velocità da distanze e tempi)
  - Utilizzare svariate funzioni statistiche (ad es., conteggi, somme, medie, mediane)
- Assieme tidying e transforming vengono anche detti **wrangling**, dato che spesso si deve "bisticciare" con i dati per trasformarli in forma naturale

# Visualize e model

- Completate le fasi precedenti, ci si può concentrare su due forme di generazione delle conoscenze:
  - **Visualizzazione**
  - **Modellizzazione**
- Questi strumenti hanno ruoli complementari, con relativi punti di forza e di debolezza
- In ogni analisi reale si itera tra le due più e più volte

# Visualize

- La **visualizzazione** è un attività umana fondamentale
- Una buona visualizzazione mostra cose insaspettate, o solleva nuove domande relative ai dati
- Una buona visualizzazione può anche suggerire che ci si sta ponendo le domande sbagliate, o che si devono usare dati diversi
- Le visualizzazioni **non scalano** particolarmente bene a causa della limitata capacità umana nell'interpretarle



# Model

- I **modelli** sono degli strumenti complementari alla visualizzazione
- Si pongono l'obiettivo di fornire un riassunto dei dati a dimensionalità ridotta
- Idealmente, un modello cattura un *segnale* vero (ad es., un pattern generato da un fenomeno d'interesse) e ignora il *rumore* (ad es., una variazione casuale al quale non siamo interessati)
- I modelli sono fondamentalmente modelli matematici o computazionali, pertanto scalano molto bene
- Tuttavia, "*la mappa non è il territorio*": ogni modello fa delle assunzioni; questo fa la differenza tra realtà e modellizzazione della realtà

# Communicate


- L'ultima fase della Data Science è la **comunicazione**
- Questa è una parte cruciale di ogni progetto di analisi
- Non importa quanto:
  - buono sia il modello
  - chiare siano le visualizzazioni
  - agevolmente questi consentono di comprendere i dati
  - se poi non li si comunica efficacemente ad altri e al se stessa/o del futuro

## INTRODUZIONE

# CHE COSA SONO I DATI?

Ogni pianta, ogni persona e ogni interazione in cui siamo coinvolti può essere mappata, quantificata e misurata. Tutte le misurazioni sono ciò che noi chiamiamo dati.


Una volta che imparerai a individuare questi numeri invisibili, inizierai a vederli ovunque, in ogni cosa.



# PERCHÉ SONO IMPORTANTI?

I DATI RACCOLTI NELLA VITA QUOTIDIANA POSSONO OFFRIRCI UNO SPACCATO DEL MONDO, TROPPO COME UNA FOTO PUÒ CATTURARE MOMENTI NEL TEMPO. INOLTRE, POSSONO ESSERE USATI PER DESCRIVERE I FATTORI NASCOSTI IN OGNI ASPETTO DELLA NOSTRA VITA, DALLA NOSTRA ESISTENZA DIGITALE AL MONDO DELLA NATURA.

VEDENDO IL MONDO ATTRAVERSO IL FILTRO DEI DATI, E DISCORANDO I PATTERN CHE SCOPRIAI IN OGNI DETTAGLIO DELLA TUA VITA, PUOI INCORAGGIARE TE STESSO A VEDERE CIÒ CHE TI CIRCONDA CON PIÙ ATTENZIONE E AD ESSERE PIÙ IN ARMONIA CON IL MONDO E CON TE STESSO.




TOP GLOBAL CONCERNS BY LIKELIHOOD, CITED BY EXPERTS, 2009-2019

MENTIONED SEVEN TIMES IN THE PAST 10 YEARS

TOP RISK IN 2019

■ BIGGEST CONCERNS IN 2019  
■ MENTIONED IN PREVIOUS YEARS




help to keep the ocean's ecosystem in balance.

The



UNIVERSITÀ DEGLI STUDI DI UDINE  
hic sunt futura

### Whaling History



Bubble netting is a unique hunting method that some humpbacks use to catch fish.

It's Time to end the Cruel Slaughter of Whales and leave these magnificent creatures alone!

### Families Considered Whales



### THE PLACES WHERE THE WHALES ARE




Ship strikes can injure or kill humpbacks!

1.000+ The number of defenseless whales killed every year by Japan, Iceland and Norway.

Donate Take Action!




### WORLD CONTRIBUTION






# NLP (Natural Language Processing)

- sottobranca di linguistica, informatica e intelligenza artificiale
- elaborare e analizzare grande quantità di dati di linguaggio naturale
- Applicazioni: **Sentiment analysis** e **Text Summarization**



# Tool per la Scienza dei dati



# R

R è un ambiente software libero per effettuare calcoli statistici e produrre visualizzazioni grafiche. È utile in tutte le fasi del workflow. Punti di forza:

1. **Capacità:** offre un vasto insieme di funzionalità
2. **Comunità:** vanta una comunità di utenti molto numerosa
3. **Prestazioni:** è piuttosto veloce (se eseguito in memoria centrale)

Pagina web: [r-project.org](http://r-project.org)



# RStudio

RStudio è un ambiente di sviluppo integrato (IDE) per R che include:

- un terminale
- un editor di testo con colorazione della sintassi che supporta la diretta esecuzione del codice
- strumenti per la visualizzazione dei grafici
- uno storico
- un debugger
- supporto alla gestione dello spazio di lavoro

```
1 library(nycflights13) ## package containing flights dataset
2 library(lubridate)
3 library(dplyr)
4 library(ggplot2)
5
6 head(flights, n = 3)
7 daily <- flights %>%
8   mutate(date = make_date(year, month, day)) %>%
9   count(date) %>%
10  mutate(wday = wday(date, label = TRUE))
11 head(daily, n = 3)
12 ggplot(daily, aes(wday, n)) +
13   geom_boxplot(outlier.colour = "hotpink") +
14   labs(x = "Weekday", y = "Flights",
15        subtitle = "Number of 2013 New York Flights Each Weekday")
16
```

Global Environment

Data


daily 365 obs. of 3 variables

\$ date: Date[1:365], format: "2013-01-01" "2013-01-02" ...

\$ n : int [1:365] 842 943 914 915 720 832 933 899 902...

\$ wday: Ord.factor w/ 7 levels "Sun"<"Mon"<"Tue"<...: 3 ...

```
~/Documents/Flights/
# A tibble: 3 x 19
  year month  day dep_time sched_dep_time dep_delay arr_time sched_arr_time arr_delay carrier
  <int> <int> <int> <int>         <int>         <dbl> <int>         <int>         <dbl> <chr>
1  2013     1     1     517           515             2       830           819           11 UA
2  2013     1     1     533           529             4       850           830           20 UA
3  2013     1     1     542           540             2       923           850           33 AA
# ... with 9 more variables: flight <int>, tailnum <chr>, origin <chr>, dest <chr>, air_time <dbl>,
# distance <dbl>, hour <dbl>, minute <dbl>, time_hour <dtm>
> daily <- flights %>%
+   mutate(date = make_date(year, month, day)) %>%
+   count(date) %>%
+   mutate(wday = wday(date, label = TRUE))
> head(daily, n = 3)
# A tibble: 3 x 3
  date          n wday
  <date>    <int> <ord>
1 2013-01-01   842 Tue
2 2013-01-02   943 Wed
3 2013-01-03   914 Thu
> ggplot(daily, aes(wday, n)) +
```



# Markdown

- Markdown è un linguaggio di markup con una sintassi del testo semplice
- progettata per essere convertita in HTML e in molti altri formati

<https://markdownlivepreview.com/> →

```
1 # Markdown syntax guide
2
3 ## Headers
4
5 # This is a Heading h1
6 ## This is a Heading h2
7 ##### This is a Heading h6
8
9 ## Emphasis
10
11 *This text will be italic*
12 _This will also be italic_
13
14 **This text will be bold**
15 __This will also be bold__
16
17 _You **can** combine them_
18
19 ## Lists
20
21 ### Unordered
22
23 * Item 1
24 * Item 2
25 * Item 2a
26 * Item 2b
27
28 ### Ordered
29
30 1. Item 1
31 1. Item 2
32 1. Item 3
33   1. Item 3a
34   1. Item 3b
35
36 ## Images
37
38 ![This is a alt text.](/image
39 /sample.png "This is a sample
40 image.")
41
42 ## Links
```

## Markdown syntax guide

### Headers

This is a Heading h1

This is a Heading h2

This is a Heading h6

### Emphasis

*This text will be italic*  
*This will also be italic*

**This text will be bold**  
**This will also be bold**

*You can combine them*

### Lists

#### Unordered

- Item 1
- Item 2
- Item 2a
- Item 2b

# R and RMarkdown

- Combiniamo assieme codici R ed markdown
- Programmiamo e presentiamo contemporaneamente

The screenshot shows the RStudio interface with two tabs: 'Presentation.Rmd' and 'styles.css'. The editor displays R Markdown code with line numbers 1 through 36. The code is organized into three sections, each highlighted with a dashed border:

- Prologo (green dashed border):** Lines 1-11. A YAML front-matter block:

```
1 ---
2 title: "Data Science in pratica"
3 author: "Eddy Maddalena & Kevin Roitero"
4 output:
5   ioslides_presentation:
6     css: styles.css
7     incremental: false
8 editor_options:
9   chunk_output_type: inline
10 ---
```
- R (blue dashed border):** Lines 12-15. An R code chunk:

```
12 ```{r setup, include=FALSE}
13 library(tufte)
14 knitr::opts_chunk$set(cache = FALSE, message = TRUE, warning = TRUE)
15 ```
```
- Markdown (magenta dashed border):** Lines 17-35. A section titled 'Scaletta' with a list of topics and a 'Presentazioni' section with HTML code for a slide:

```
17 ## Scaletta
18
19 * Presentazioni - 5 minuti
20 * Panoramica sulla data science? 50 minuti
21 * Panoramica su R ed RStudio ? 20 minuti
22 * Pausa - 10 minuti
23 * Parte pratica:
24   * Esempi - 30 minuti
25   * Esercizi - 30 minuti
26
27 ## Presentazioni
28
29 <div class="block_50" />
30 
31 <p style="font-size:.9em;" >
32   <b>Eddy Maddalena</b> <br>
33   eddy.maddalena&#64;uniud.it
34   <br> http://eddy.maddalena.net</p>
35 </div>
```

The rendered output on the right side of the editor shows three slides:

- Prologo:** A white slide with the title 'Prologo' in green text.
- R:** A grey slide with the letter 'R' in blue text.
- Markdown:** A white slide with the title 'Markdown' in magenta text.

At the bottom of the editor, the status bar shows '5:7 # Presentazioni' and 'R Markdown'.

+ Create

🏠 Home

🏆 Competitions

📁 Datasets

<> Code

💬 Discussions

🎓 Courses

∨ More

📁 Your Work

RECENTLY VIEWED

🎮 Video Game Sales

🎮 Videogame Sales

🎮 Minecraft Composting ...

🎮 Fortnite Statistics Corr...

🎮 COD Players data visu...

All datasets

Computer Science

Education

Classification

Computer Vision

NLP

Data Visualization

Pre-Trained Model



### Animated Movies IMDb

Tarun R Jain · Updated 6 days ago  
Usability 10.0 · 10 kB  
1 File (CSV)

◀ 14



### Airbnb-NYC-Cleaned

sandeep majumdar · Updated 6 days ago  
Usability 10.0 · 7 MB  
1 File (CSV)

◀ 17



### Top 6 Economies in the world by GDP

Charan Chandrasekaran · Updated 6 da...  
Usability 9.1 · 22 kB  
1 File (CSV)

◀ 9



### Chicago Bicycle Rent Usage

Gunnar N. · Updated 19 days ago  
Usability 9.1 · 455 MB  
28 Files (CSV)

◀ 18

## 🔄 Popular Datasets

See All



### Data Science Job Salaries

Ruchi Bhatia · Updated 3 months ago  
Usability 10.0 · 8 kB  
1 File (CSV)



### AMEX data - integer dtypes - parquet format

raddar · Updated 3 months ago  
Usability 4.4 · 4 GB  
2 Files (other)



### House Rent Prediction Dataset

Sourav Banerjee · Updated 11 days ago  
Usability 10.0 · 84 kB  
2 Files (CSV, other)



### McDonald's India : Menu Nutrition Dataset

Deep Contractor · Updated a month ago  
Usability 9.4 · 5 kB  
1 File (CSV)



## Riferimenti

[1] <https://www.thebalancecareers.com/>

[2] <https://builtin.com/salaries/data-analytics/data-scientist>