# Codifica dei dati

## Informatica@DSS 2019/2020 — II canale

**Massimo Lauria** <massimo.lauria@uniroma1.it>
https://massimolauria.net/courses/informatica2019/

# Rappresentazione dei dati

# Zero e uno

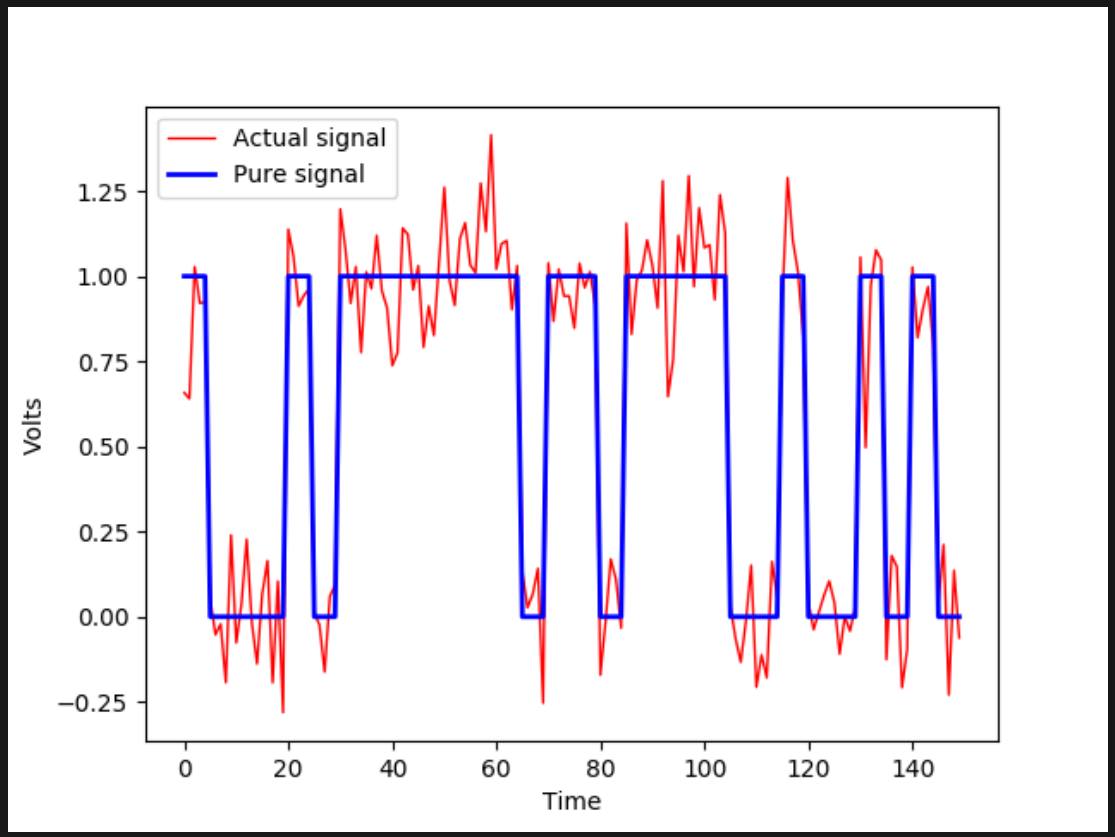


Un bit di informazione

- 0 o 1
- Vero o Falso
- tensione alta o bassa
- interruttore acceso o spento

Più di due stati?

- e.g. macchine di Turing
- maggiori errori

# Due stati sono pochi: insiemi di bit

$n$ bit assumono $2^n$ configurazioni

| | |
|---|---|
| 1 byte | 8 bit |
| 1 KB | $2^{10}$ = 1024 byte |
| 1 MB | $2^{10}$ KB = 1024 KB |
| 1 GB | $2^{10}$ MB = 1024 MB |
| ... | ... |

# Codifica di dati

Il significato di una sequenza di bit dipende dalla sua interpretazione

Utilizzare due interpretazioni differenti per gli stessi dati

- può causare errori nel programma
- può corrompere i dati
- può essere usato per violare la sicurezza

# In Python ogni dato ha un tipo

```
print(type(5))        # il tipo dell'espressione 5                    1
print(type('ciao'))   # il tipo dell'espressione 'ciao'               2
print(type(3.2))      # il tipo dell'espressione 3.2                  3
print(type(5.0))      # il tipo dell'espressione 5.0                  4
print(3.2 + 5)        # somma tra dati di tipo diverso                5
print(type(3.2 + 5)) # il tipo del risultato                          6
5 + 'ciao'    # altra somma tra dati di tipo diverso                  7
```

```
<class 'int'>
<class 'str'>
<class 'float'>
<class 'float'>
8.2
<class 'float'>
Traceback (most recent call last):
  File "<stdin>", line 1, in <module>
  File "/tmp/babel-oW6QHu/python-hQAwIp", line 7, in <module>
    5 + 'ciao'    # altra somma tra dati di tipo diverso
TypeError: unsupported operand type(s) for +: 'int' and 'str'
```

# Codifica di numeri

**La notazione decimale (i.e. in base $10$) usa cifre da $0$ a $9$**

**E.g.** $45903 = 4 \cdot 10^4 + 5 \cdot 10^3 + 9 \cdot 10^2 + 0 \cdot 10^1 + 3 \cdot 10^0$

**Se ci sono solo le cifre $0$ e $1$ ha senso usare la base $2$**

**E.g.** $110101 = 1 \cdot 2^5 + 1 \cdot 2^4 + 0 \cdot 2^3 + 1 \cdot 2^2 + 0 \cdot 2^1 + 1 \cdot 2^0$

# Notazione binaria (E.g. 4 bit)

$$b_3 b_2 b_1 b_0 = b_3 \cdot 2^3 + b_2 \cdot 2^2 + b_1 \cdot 2^1 + b_0 \cdot 2^0$$

$b_3$ è il bit più significativo; $b_0$ è il bit meno significativo

| 8421 | | | 8421 | | |
|---|---|---|---|---|---|
| 0000 | 0 | 0 | 1000 | 8 | 8 |
| 0001 | 1 | 1 | 1001 | 8+1 | 9 |
| 0010 | 2 | 2 | 1010 | 8+2 | 10 |
| 0011 | 2+1 | 3 | 1011 | 8+2+1 | 11 |
| 0100 | 4 | 4 | 1100 | 8+4 | 12 |
| 0101 | 4+1 | 5 | 1101 | 8+4+1 | 13 |
| 0110 | 4+2 | 6 | 1110 | 8+4+2 | 14 |
| 0111 | 4+2+1 | 7 | 1111 | 8+4+2+1 | 15 |

# Notazione binaria ($n$ bit)

Caso $n$ bit: $b_{n-1} \dots b_0 = \sum_{i=0}^{n-1} b_i \cdot 2^i$.

8 bit rappresentano $2^8 = 256$ valori

$$\{0, 1, 2, \dots, 255\} \tag{1}$$

16 bit rappresentano $2^{16} = 65536$ valori

$$\{0, 1, 2, \dots, 65535\} \tag{2}$$

Domanda: ogni intero positivo ha esattamente una rappresentazione binaria?

# Stampare in notazione binaria

Potete usare Python per fare le conversioni

```
# l'operatore ** esegue l'elevazione a potenza
numero = 2**10 + 2**7 + 2**5 + 2**3 + 1

print("Base 10 - {}".format(numero))
print("Base  2 - {:b}".format(numero))
```

```
Base 10 - 1193
Base  2 - 10010101001
```

# Notazione binaria è scomoda

**(dec.)** 123456789 **=** **(bin.)** 111010110111100110100010101

Base 2

- adatta per il computer
- numeri troppo lunghi e scomodi da leggere

Base 10

- più compatta e leggibile
- le cifre corrispondono male con quelle in base 2

# Abbreviazione della notazione binaria

Base 16 (notazione esadecimale)

{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E, F}

con A = 10, B = 11, C = 12, D = 13, E = 14, F = 15

$$\underbrace{0111}_{7}\ \underbrace{0101}_{5}\ \underbrace{1011}_{B}\ \underbrace{1100}_{C}\ \underbrace{1101}_{D}\ \underbrace{0001}_{1}\ \underbrace{0101}_{5}$$

**(dec.)** 123456789 **= (hex.)** 75BCD15

**(dec.)** 175 **= (bin.)** 10101111 **= (hex.)** AF

# Usiamo python per verificare i conti

$$\underbrace{0111}_{7}\ \underbrace{0101}_{5}\ \underbrace{1011}_{B}\ \underbrace{1100}_{C}\ \underbrace{1101}_{D}\ \underbrace{0001}_{1}\ \underbrace{0101}_{5}$$

**(dec.)** 123456789 **=** **(hex.)** 75BCD15

```
numero = 123456789                                  1
                                                    2
print("Base 10 - {}".format(numero))                3
print("Base  2 - {:b}".format(numero))              4
print("Base 16 - {:x}".format(numero))              5
```

```
Base 10 - 123456789                                 1
Base  2 - 111010110111100110100010101              2
Base 16 - 75bcd15                                   3
```

# Rappresentazione di byte

È scomodo scrivere/leggere 8 bit per esteso.
Normalmente un byte è scritto come

- un numero da $0$ a $255$, oppure
- un numero esadecimale di due cifre, da $00$ a $FF$.

# I numeri esadecimali in Python

In python gli esadecimali si scrivono col prefisso `0x`

```
print(0xFe, 0xfE, 0xfe)                    1
print(0XC3)                                2
print(0x2D3Ac463e  + 4524)                 3
```

```
254 254 254
195
12141221866
```

# Ricapitolando

- I numeri codificati come sequenze di $0$ e $1$…
- …seguendo la notazione in base 2
- Base 16 come abbreviazione di base 2.

# Python e numeri molto grandi

```
print(3**312 + 7**94)                                                    1
```

```
72749744522375265125206295317964396725
53343286682495257583990369543852572160
39907289132821352297259222089567082614
19259341094593387593588827435562290
```

- Python permette numeri grandi a piacere
- CPU opera su numeri di taglia fissa, e.g. $64$ bit
- C, C++, Java, .. fanno lo stesso
- al massimo $2^{64}$ valori, da $-2^{63}$ a $2^{63} - 1$
- possibilità di *overflow*

# Codifica della comunicazione scritta

Studente: ‘Prof. una proroga?’

‘Non se ne parla nemmeno.’

Studente: ‘Per favoooore!’

‘Assolutamente no.’

Studente: ‘Che bastardo…’

‘Come?’

Studente: ‘Oops! Sbagliato finestra…’

# Codifica della comunicazione scritta

Studente: [80, 114, 111, 102, 46, 32, 117, 110, 97, 32,… ]

[78, 111, 110, 32, 115, 101, 32, 110, 101, 32, 112, 97, …]

Studente: [80, 101, 114, 32, 102, 97, 118, 111, 111, 111, 111, 114, 101, 33]

[65, 115, 115, 111, 108, 117, 116, 97, 109, 101, 110, 116, 101, 32, 110, 111, 46]

Studente: [67, 104, 101, 32, 98, 97, 115, 116, 97, 114, 100, 111, 46, 46, 46]

[67, 111, 109, 101, 63]

Studente: [79, 111, 112, 115, 33, 32, 83, 98, 97, 103, 108, 105, 97, …]

# Codifica di testi — ASCII

**Binario:** $0b_6b_5b_4b_3b_2b_1b_0$

**Esadecimale:** $h_1h_0$ **con** $0 \leqslant h_1 \leqslant 7$.

ASCII Code Chart

| | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | A | B | C | D | E | F |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 0 | NUL | SOH | STX | ETX | EOT | ENQ | ACK | BEL | BS | HT | LF | VT | FF | CR | SO | SI |
| 1 | DLE | DC1 | DC2 | DC3 | DC4 | NAK | SYN | ETB | CAN | EM | SUB | ESC | FS | GS | RS | US |
| 2 | | ! | | # | $ | % | & | | ( | ) | * | + | , | - | . | / |
| 3 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | : | ; | < | = | > | ? |
| 4 | @ | A | B | C | D | E | F | G | H | I | J | K | L | M | N | O |
| 5 | P | Q | R | S | T | U | V | W | X | Y | Z | [ | \ | ] | ^ | _ |
| 6 | ` | a | b | c | d | e | f | g | h | i | j | k | l | m | n | o |
| 7 | p | q | r | s | t | u | v | w | x | y | z | { | \| | } | ~ | DEL |

Figure: Tabella ASCII (fonte:Wikipedia)

"Informatica" = (73, 110, 102, 111, 114, 109, 97, 116, 105, 99, 97)

# Codifica di testi — ASCII Estesi

La codifica ASCII usa 8 bit ma prevede solo 128 valori.
Il bit più significativo è sempre 0.

Esistono varie estensioni di ASCII (e.g. Latin-1)

- usano le stringhe $1b_6b_5b_4b_3b_2b_1b_0$
- caratteri locali e/o con accenti (e.g. à, è, é, ì, ò, ù)
- incompatibili tra loro

# Codifica di testi — Unicode e UTF-8

Unicode: una tabella per tutte le lingue

- 21 bit per simbolo = ca. 2 milioni
- facilita la comunicazione tra lingue diverse
- supporto per scrittura bidirezionale
- per i testi ASCII è più costosa

UTF-8 è una rappresentazione di Unicode

- lunghezza variabile da 1 a 4 byte
- identica ad ASCII per i primi 128 simboli
- lo standard attuale

# Codifica di testi — interpretazione ambigua

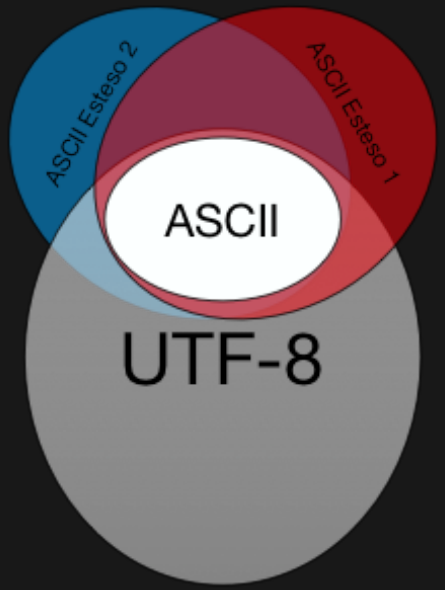


Esempio 1: ’Caipiriña’ viene codificato in Latin-1

[67, 97, 105, 112, 105, 114, 105, 241, 97]

il ricevitore decodifica in UTF-8 e segnala errore.

Esempio 2: ’Caipiriña’ viene codificato in UTF-8

[67, 97, 105, 112, 105, 114, 105, 195, 177, 97]

il ricevitore decodifica in Latin-1 ’CaipiriÃ±a’

# Immagini - bitmap

Bitmap: Griglia di “pixel” colorati con coordinate $(x, y)$

$$\begin{bmatrix} 0,0 & 1,0 & 2,0 & 3,0 & 4,0 \\ 0,1 & 1,1 & 2,1 & 3,1 & 4,1 \\ 0,2 & 1,2 & 2,2 & 3,2 & 4,2 \\ 0,3 & 1,3 & 2,3 & 3,3 & 4,3 \\ 0,4 & 1,4 & 2,4 & 3,4 & 4,4 \\ 0,5 & 1,5 & 2,5 & 3,5 & 4,5 \\ 0,6 & 1,6 & 2,6 & 3,6 & 4,6 \end{bmatrix}$$

# Risoluzione della griglia



Dimensione immagine =

$$\text{Altezza} \times \text{Larghezza} \times \text{byte(colore)}$$

Spazio:

- Bianco e nero: 1 bit per pixel
- R,G,B : tipicamente 3 byte per pixel
- Tavolozza: $\log_2$(#colori) per pixel + Dim(tavolozza)

# Codifica di segnali: musica, video, …

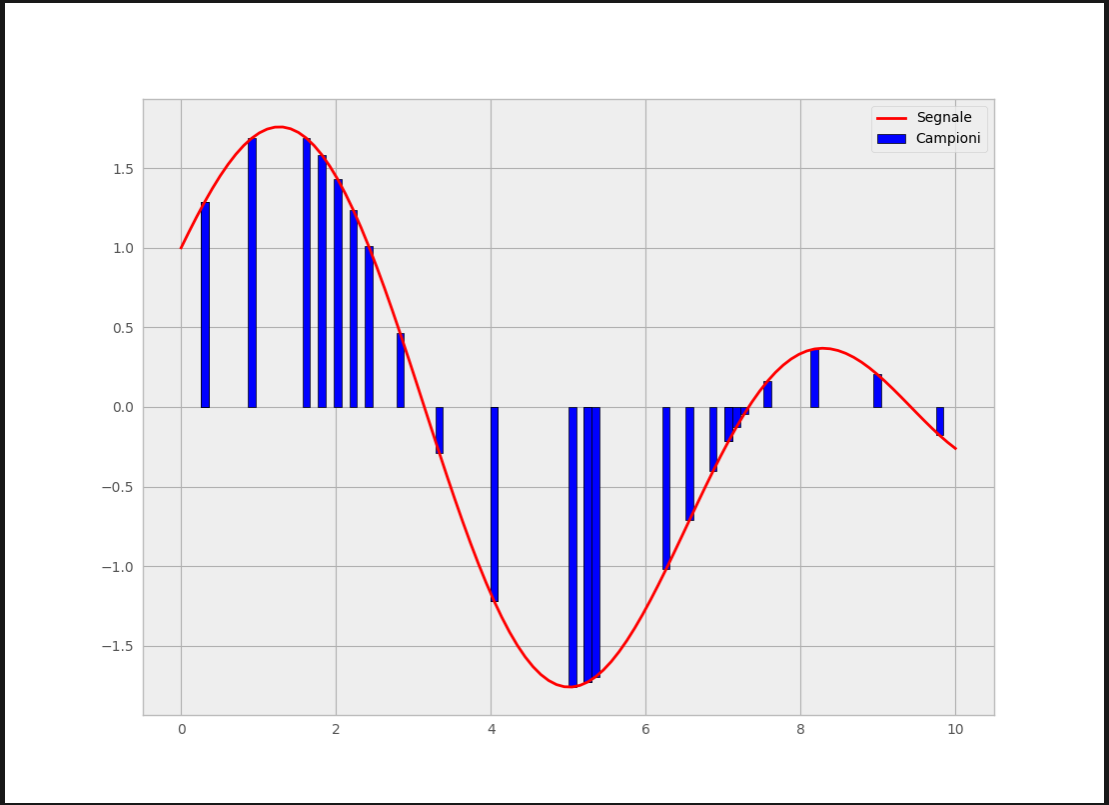


- discretizzazione
- risoluzione
- precisione vs costo
- compressione

# Esercizio

Decodificate il testo seguente, codificato in ASCII

[76, 101, 103, 103, 101, 116, 101, 32, 105, 108, 32, 109, 97, 116, 101, 114, 105, 97, 108, 101, 32, 80, 82, 73, 77, 65, 32, 100, 105, 32, 118, 101, 110, 105, 114, 101, 32, 97, 32, 108, 101, 122, 105, 111, 110, 101, 33]