

# Fondamenti di Informatica (Elettronici)

THINK JULIA – Capitolo 8a (prima parte)

6 novembre 2020

## 8. Stringhe (a)<sup>1</sup>

- 1 Caratteri
- 2 Una stringa è una sequenza
- 3 Lunghezza
- 4 Visita (Traversal)
- 5 Slices (fette) di stringa
- 6 Le stringhe sono immutabili

---

<sup>1</sup>Tratto da <https://benlauwens.github.io/ThinkJulia.jl/latest/book.html>, disponibile sotto Licenza 'Creative Commons Attribution-NonCommercial 3.0 Unported'.

Le **stringhe** **non sono** come gli interi, i `float` e i booleani.

Una stringa è una **sequenza**, il che significa che è una **collezione ordinata** di altri valori. **In questo capitolo vedremo come accedere ai caratteri che compongono una stringa**, e impareremo alcune delle **funzioni di supporto** delle **stringhe** fornite da **Julia**.

# Section 1

## Caratteri

# Standard ASCII

I parlanti di **lingua inglese** hanno familiarità con caratteri come le lettere dell'alfabeto (A, B, C, ...), i numeri e la punteggiatura comune.

Questi **caratteri sono standardizzati** e **mappati su valori interi** compresi tra 0 e 127 dallo **standard ASCII** (**American Standard Code for Information Interchange**).

Ci sono, ovviamente, **molti altri caratteri** usati in lingue **diverse dall'inglese**, comprese **varianti** dei caratteri ASCII **con accenti** e altre modifiche, script correlati come il **cirillico** e il **greco**, e script completamente estranei ad ASCII e inglese, inclusi Arabo, cinese, ebraico, hindi, giapponese e coreano.

## Standard Unicode

Lo **standard Unicode** affronta le complessità di cosa sia esattamente un carattere, ed è **generalmente accettato** come lo **standard definitivo** che affronta questo problema.

Fornisce un **numero univoco** per ogni **carattere su scala mondiale**.

Un **valore di tipo Char** rappresenta un **singolo carattere** ed è racchiuso tra **virgolette singole**:

```
julia> 'x'  
'x': ASCII/Unicode U+0078 (category Ll: Letter, lowercase)  
julia> ' '  
' ': Unicode U+01f34c (category So: Symbol, other)  
julia> typeof('x')  
Char
```

Anche gli **emoji** fanno parte dello standard **Unicode**. (`\:banana:` TAB)

## Section 2

Una stringa è una sequenza

## String = sequenza di caratteri

Una stringa è una **sequenza di caratteri**. Puoi **accedere ai caratteri** uno alla volta con l'**operatore parentesi quadre**:

```
julia> fruit = "banana"
```

```
"banana"
```

```
julia> letter = fruit[1]
```

```
'b': ASCII/Unicode U+0062 (category Ll: Letter, lowercase)
```

La seconda istruzione **seleziona il carattere numero 1 di fruit** e lo assegna a letter. L'espressione tra **parentesi quadre** è chiamata **indice**. L'indice indica **quale** carattere nella **sequenza** si desidera (da cui il nome).

Tutta l'**indicizzazione** in Julia è **basata su 1**: il **primo elemento** di qualsiasi **oggetto indicizzato** con numeri interi **si trova all'indice 1** e l'**ultimo elemento** all'**indice end**.



## Accesso alle stringhe tramite indice

```
julia> fruit[end]
'a': ASCII/Unicode U+0061 (category Ll: Letter, lowercase)
```

Come **indice** si può usare un'**espressione** che contiene **variabili e operatori**:

```
julia> i = 1
1
julia> fruit[i+1]
'a': ASCII/Unicode U+0061 (category Ll: Letter, lowercase)
julia> fruit[end-1]
'n': ASCII/Unicode U+006e (category Ll: Letter, lowercase)
```

Ma il **valore dell'indice** **deve essere** un numero **intero**. Altrimenti si ottiene:

```
julia> letter = fruit[1.5]
ERROR: MethodError: no method matching getindex(::String, ::Float64)
```

## Section 3

# Lunghezza

## Restituisce il numero di elementi di un tipo indicizzato

```
julia> fruits = "🍌 🍏 🍐 "  
"🍌 🍏 🍐 "  
  
julia> len = length(fruits)  
3
```

## Le stringhe sono codificate con UTF-8

Le **stringhe** vengono **codificate** utilizzando **la codifica UTF-8**. UTF-8 è una codifica **a larghezza variabile**, il che significa che **non tutti i caratteri** sono codificati nello **stesso numero di byte**.

La **funzione sizeof** fornisce il **numero di byte** in una **stringa**:

```
julia> sizeof("🍌")  
4
```

Poiché **un'emoji è codificata in 4 byte** e l'indicizzazione delle stringhe è **basata sui byte**, il quinto elemento di `fruits` è l'**inizio** del **carattere successivo**.

## Usa “nextind” per ottenere gli indici delle stringhe

Ciò significa anche che **non ogni indice di byte** in una stringa UTF-8 è necessariamente un **indice valido per un carattere**. Se indicizzi in una stringa con un indice di byte **non valido**, viene generato un **errore**:

```
julia> fruits[2]  
ERROR: StringIndexError("🍌 🍏 🍐", 2)
```

Nel caso di `fruits`, il **carattere** è una **sequenza di quattro byte**, quindi gli indici 2, 3 e 4 non sono validi e l'**indice del carattere successivo è 5**; questo successivo indice valido **può essere calcolato da nextind (fruits, 1)**, e l'indice successivo al successivo **da nextind (fruits, 5)** e così via.

## Section 4

# Visita (Traversal)

# String traversal

Molti **calcoli** comportano l'**elaborazione di una stringa** un **carattere alla volta**.

Spesso **iniziano** dall'inizio, **selezionano** ogni carattere alla volta, **fanno qualcosa** e **continuano** fino alla fine.

Questo **modello di elaborazione** è chiamato "**traversal**" (**visita**). Un modo per **scrivere** un traversal è con un **ciclo while**:

```
index = firstindex(fruits)
while index <= sizeof(fruits)
    letter = fruits[index]
    println(letter)
    global index = nextind(fruits, index)
end
```

Questo **ciclo attraversa la stringa** e **visualizza** ogni lettera **su una riga** da sola. La condizione del ciclo è `index <= sizeof (fruit)`, quindi **quando index è maggiore** del numero di **byte nella stringa**, la condizione è **false** e il corpo del ciclo non viene eseguito.

La funzione `firstindex` **restituisce** il **primo byte valido** di `index`.

La **parola chiave global** prima di `index` indica che **si desidera riassegnare** la variabile `index` **definita in Main** (vedere Variabili globali).

## Section 5

# Slices (fette) di stringa



## Intervallo di indici

Un **segmento di una stringa** è chiamato **slice**. La **selezione** di una fetta è simile alla **selezione di un carattere**:

```
julia> str = "Julius Caesar";  
julia> str[1:6] "Julius"
```

L'**operatore [n:m]** restituisce la **parte** della stringa dal **byte "n"** al **byte "m"**. Quindi è necessaria la stessa **cautela** della indicizzazione semplice.

La **parola chiave end** può essere **utilizzata** per indicare l'**ultimo byte** della stringa:

```
julia> str[8:end]  
"Caesar"
```

## La stringa vuota

Se il **primo indice** è **maggiore del secondo** il risultato è una **stringa vuota**, rappresentata da **due virgolette doppie**:

```
julia> str[8:7]  
""
```

Una stringa **vuota non contiene caratteri** e ha **lunghezza 0**, ma a parte questo, è uguale a qualsiasi altra stringa.

### Esercizio 8-3

Continuando l'esempio, cosa pensi che **significhi** `str[:]` ? **Provalo e guarda.**

## Section 6

# Le stringhe sono immutabili

## Avviso sui tipi immutabili

Si è tentati di usare l'operatore "" sul lato sinistro di una assegnazione, con l'intenzione di cambiare un carattere in una stringa. Per esempio:

```
julia> greeting = "Hello, world!"  
"Hello, world!"  
julia> greeting[1] = 'J'  
ERROR: MethodError: no method matching setindex!(::String, ::Char,
```

Il motivo dell'errore è che le stringhe non sono modificabili, il che significa che non è possibile modificare una stringa esistente.

## Avviso sui tipi immutabili

Si è tentati di usare l'operatore "" sul lato sinistro di una assegnazione, con l'intenzione di cambiare un carattere in una stringa. Per esempio:

```
julia> greeting = "Hello, world!"  
"Hello, world!"  
julia> greeting[1] = 'J'  
ERROR: MethodError: no method matching setindex!(::String, ::Char,
```

Il motivo dell'errore è che le stringhe non sono modificabili, il che significa che non è possibile modificare una stringa esistente.

Puoi creare una nuova stringa che sia una variazione dell'originale:

```
julia> greeting = "J" * greeting[2:end]  
"Jello, world!"
```

Questo esempio concatena una nuova prima lettera con una slice di greeting. Non ha effetto sulla stringa originale.