Titolo unità didattica: Stringhe ed elaborazione di testi [09]

Titolo modulo : Algoritmi per l'elaborazione di testi [02-T]

Algoritmi di analisi di testi e di individuazione di *pattern*

Argomenti trattati:

- ✓ algoritmo di analisi delle componenti di un testo
- ✓ algoritmo di string matching
- ✓ algoritmo di matching migliore

Prerequisiti richiesti: AP-07-11-T

problema:
dato un testo (stringa), che contiene uno scritto in lingua italiana, determinare il numero di **parole** contenute nel testo (senza segni di interpunzione)

dati di input: la stringa (array testo), la sua lunghezza (variabile m)
dato di output: il numero di parole nel testo (variabile numero_parole)
costrutto ripetitivo: 1 ciclo for
operazione ripetuta (al generico passo i)**:**
considerare l'i–simo carattere della stringa testo, determinare se è iniziale di una parola e incrementare opportunamente i contatori

una **parola** è una sottostringa racchiusa tra due caratteri spazio


i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i

in_parola

numero_parole

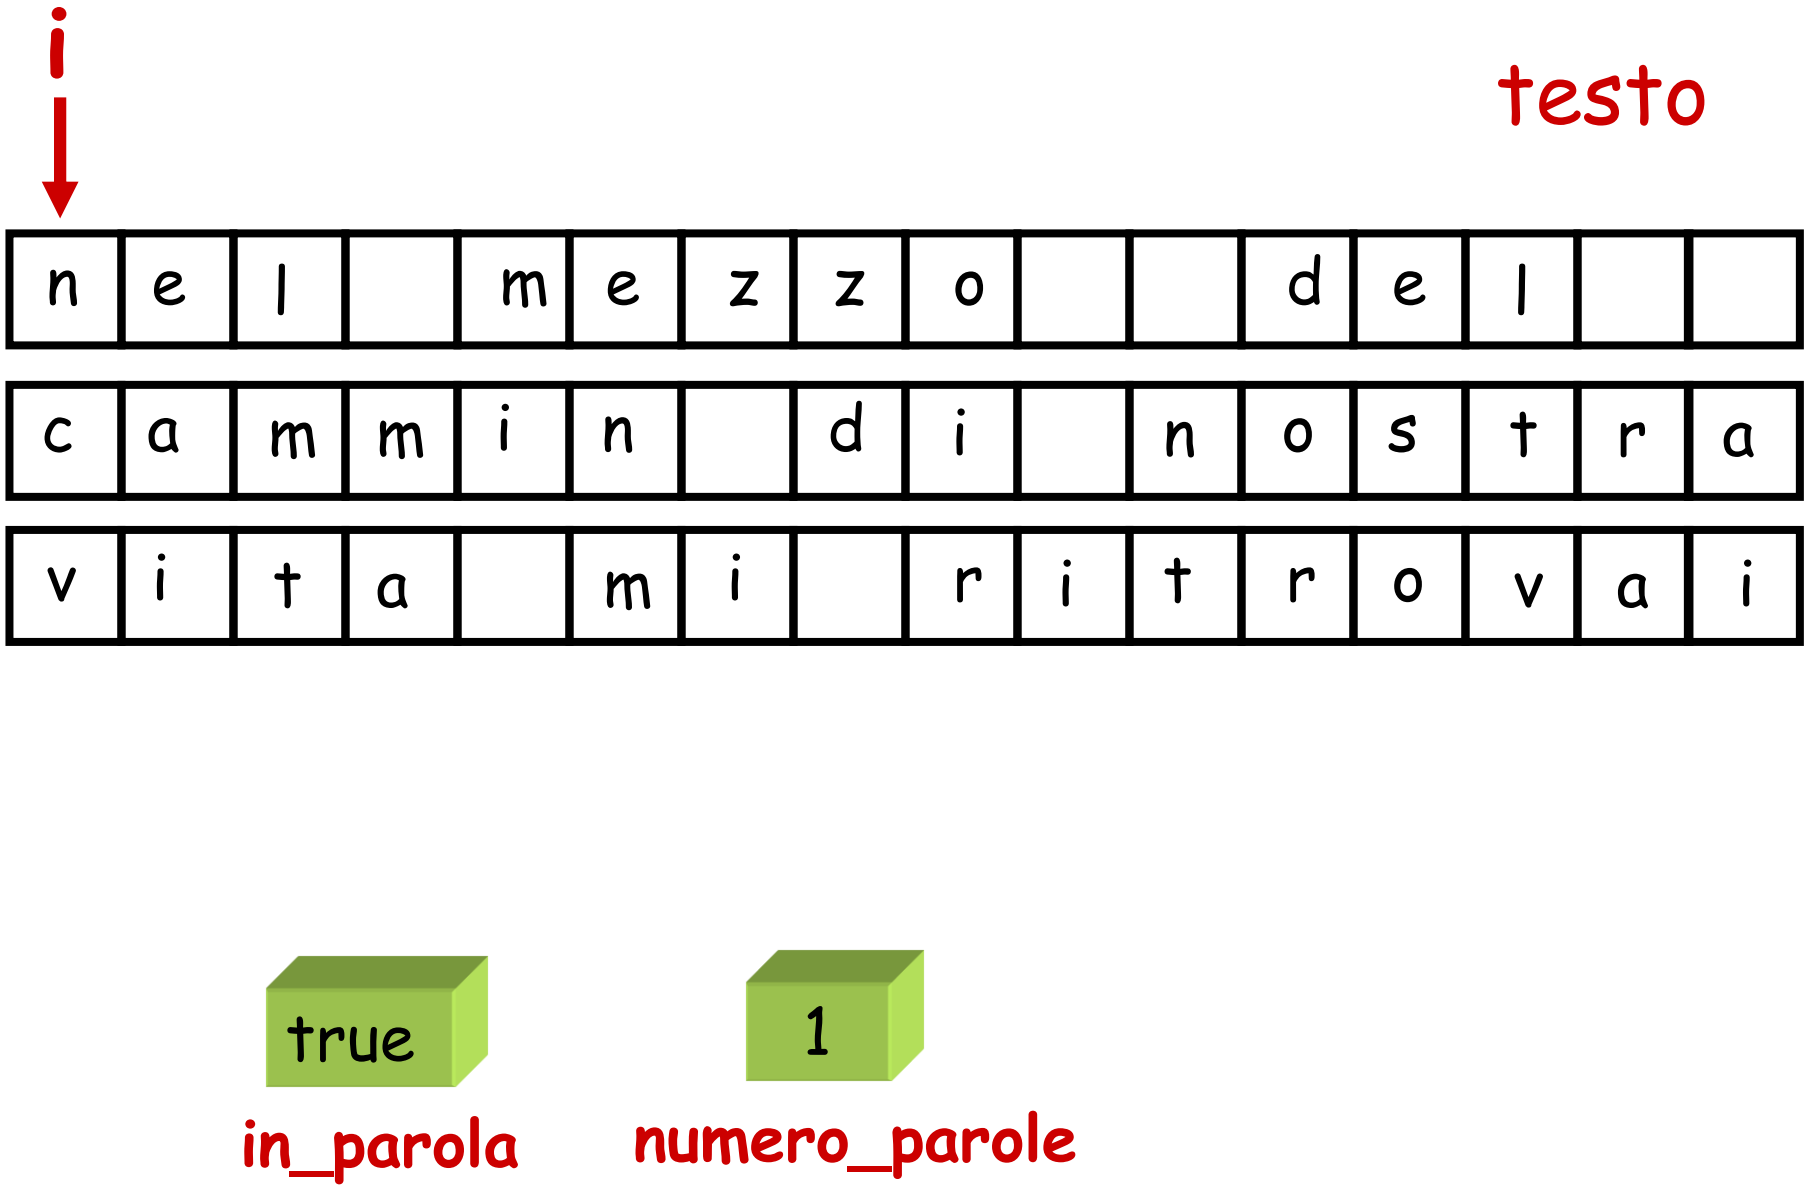
i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i
true
in_parola
1
numero_parole

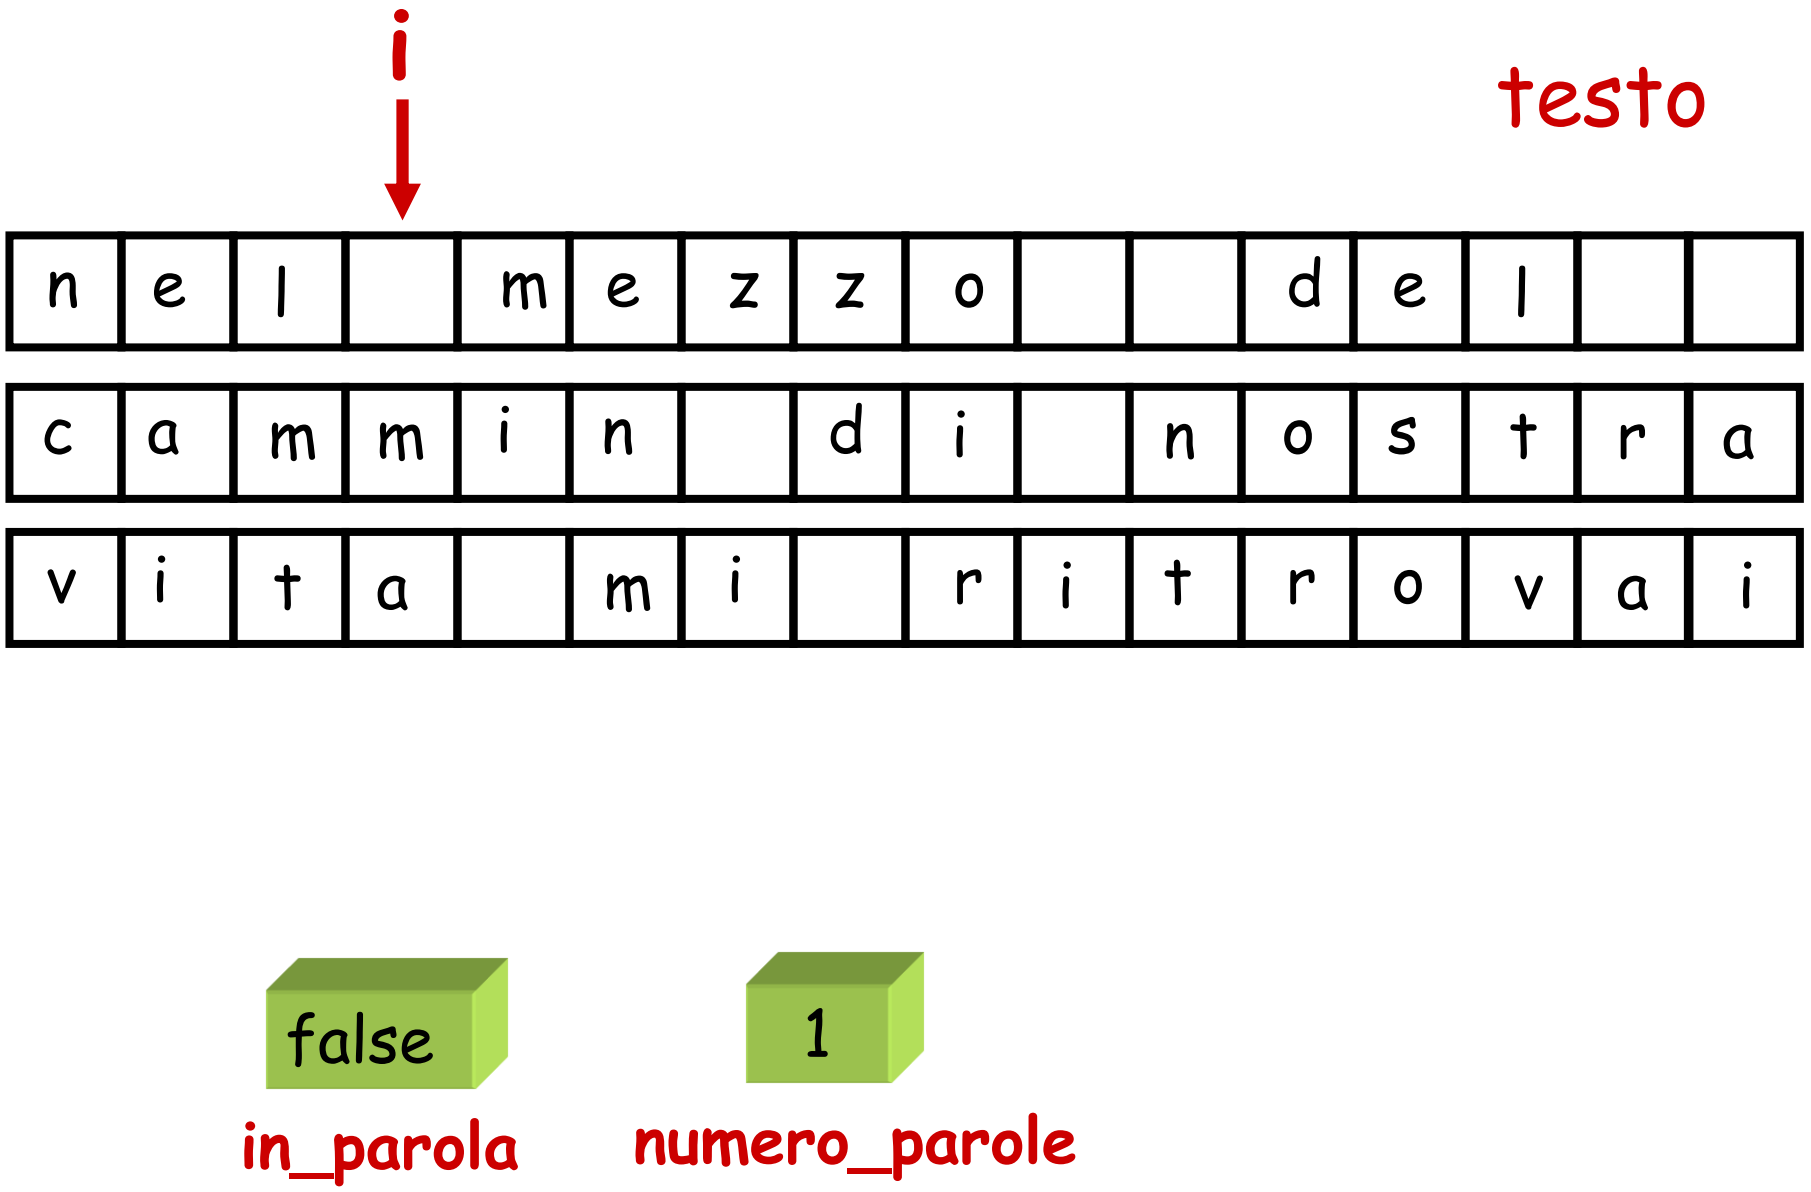
i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i
false
in_parola
1
numero_parole

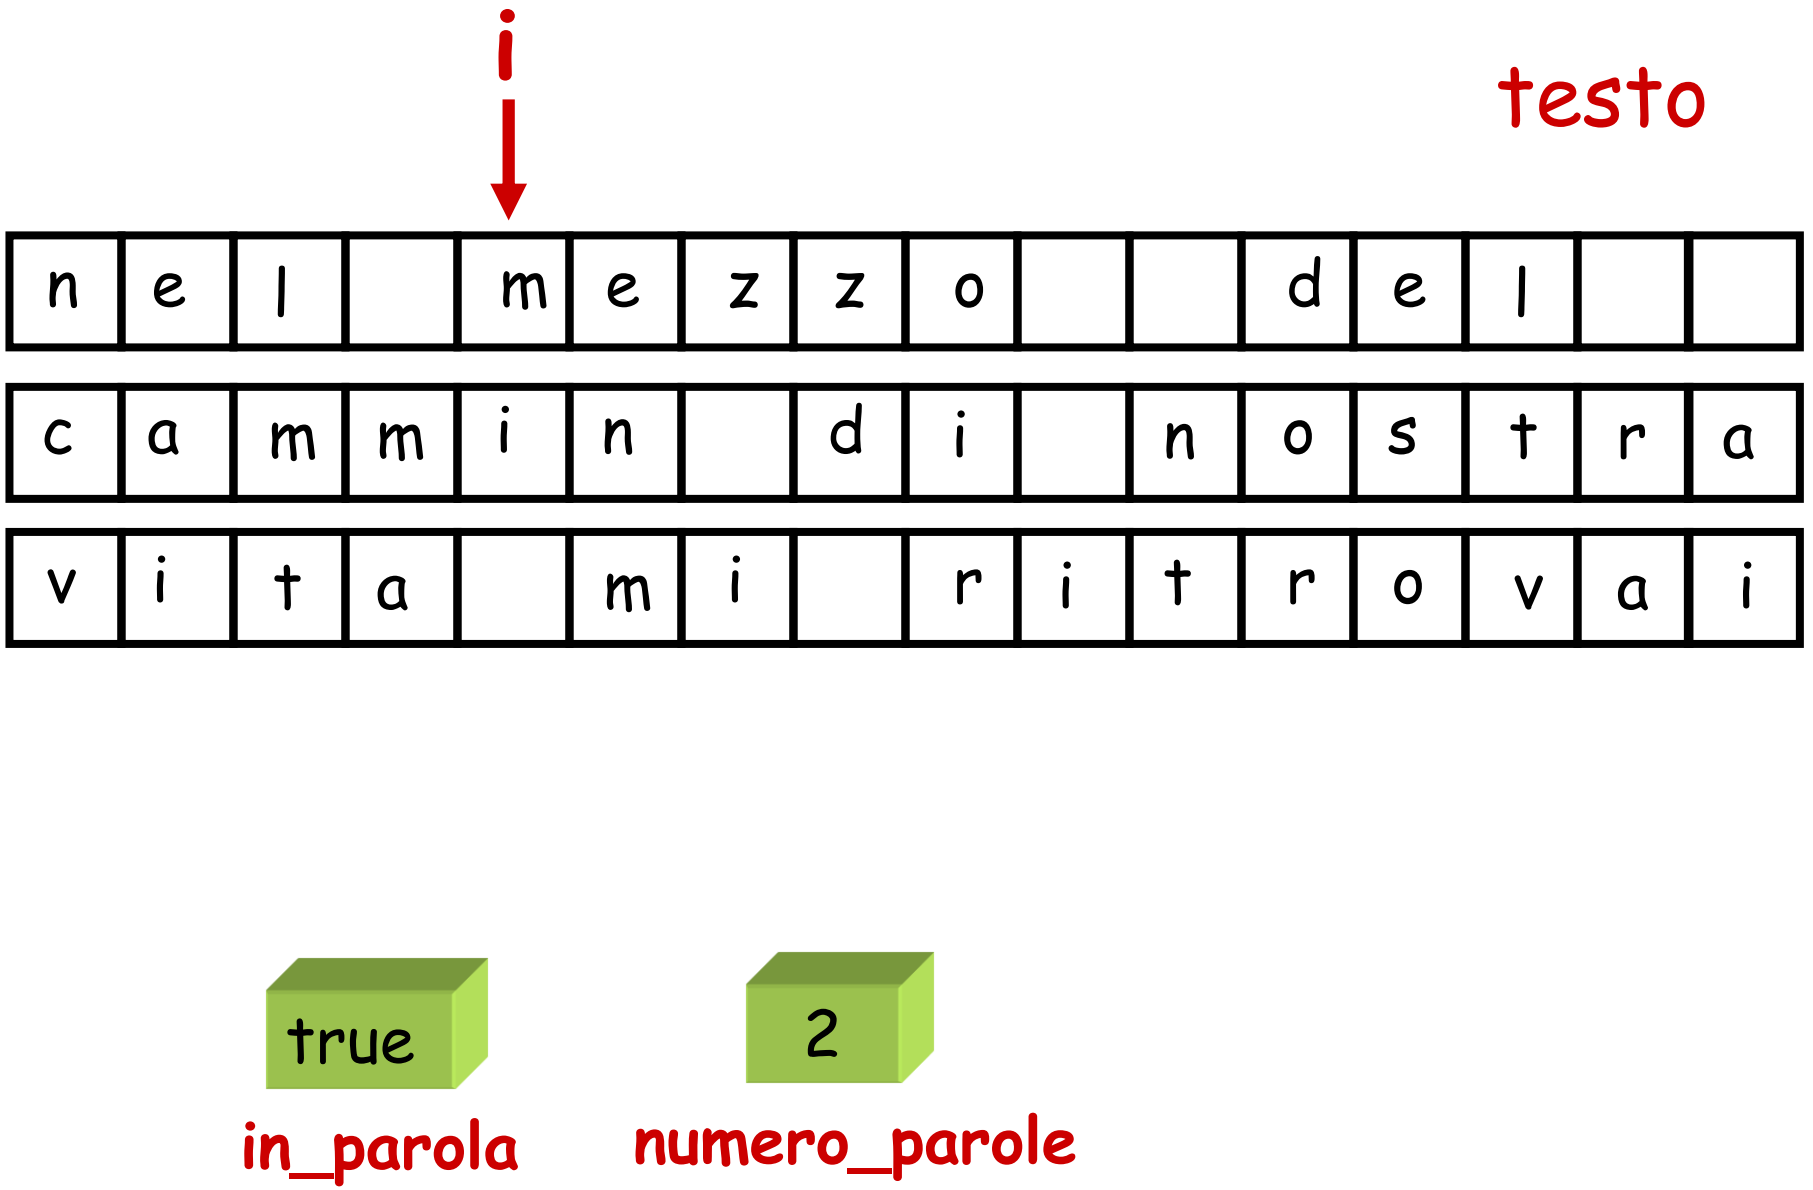
i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i
true
2
in_parola
numero_parole

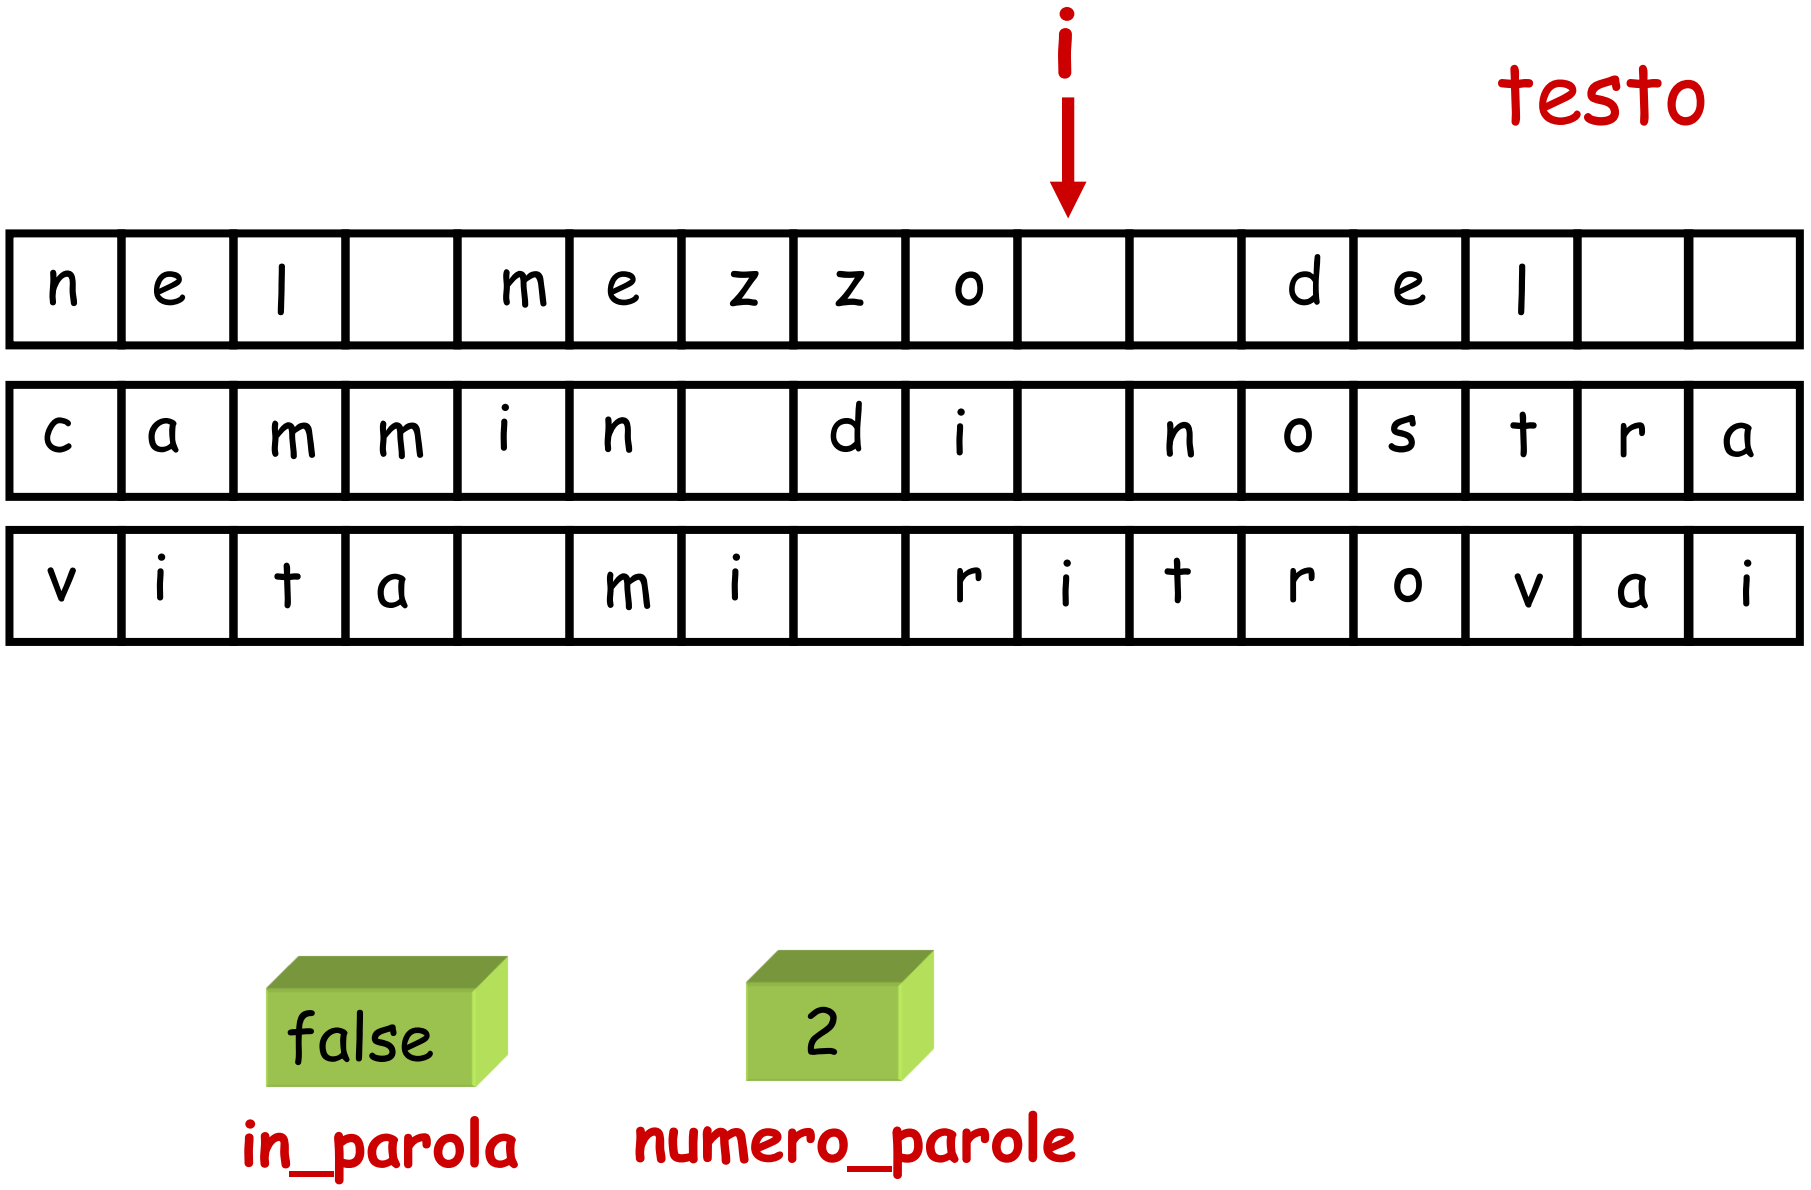
i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i
false
2
in_parola
numero_parole

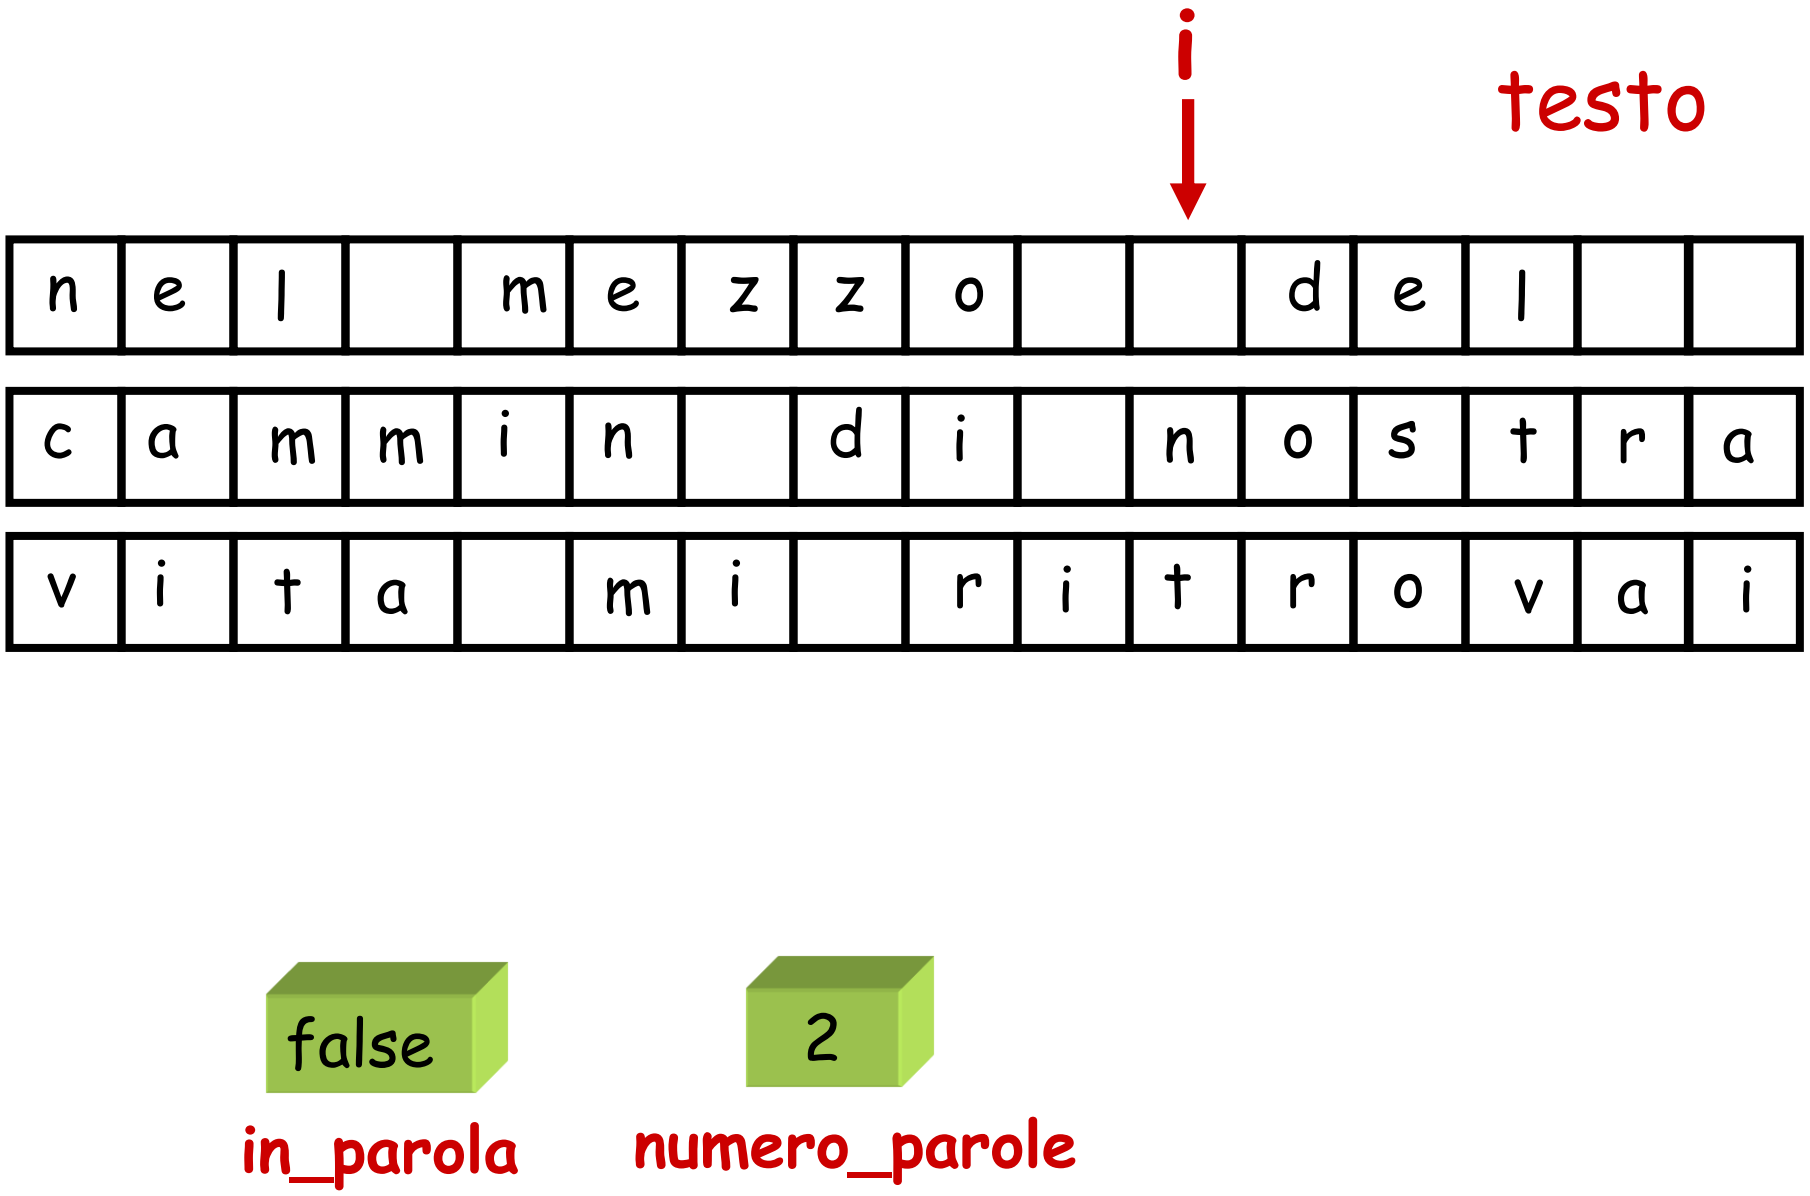
i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i
false
2
in_parola
numero_parole

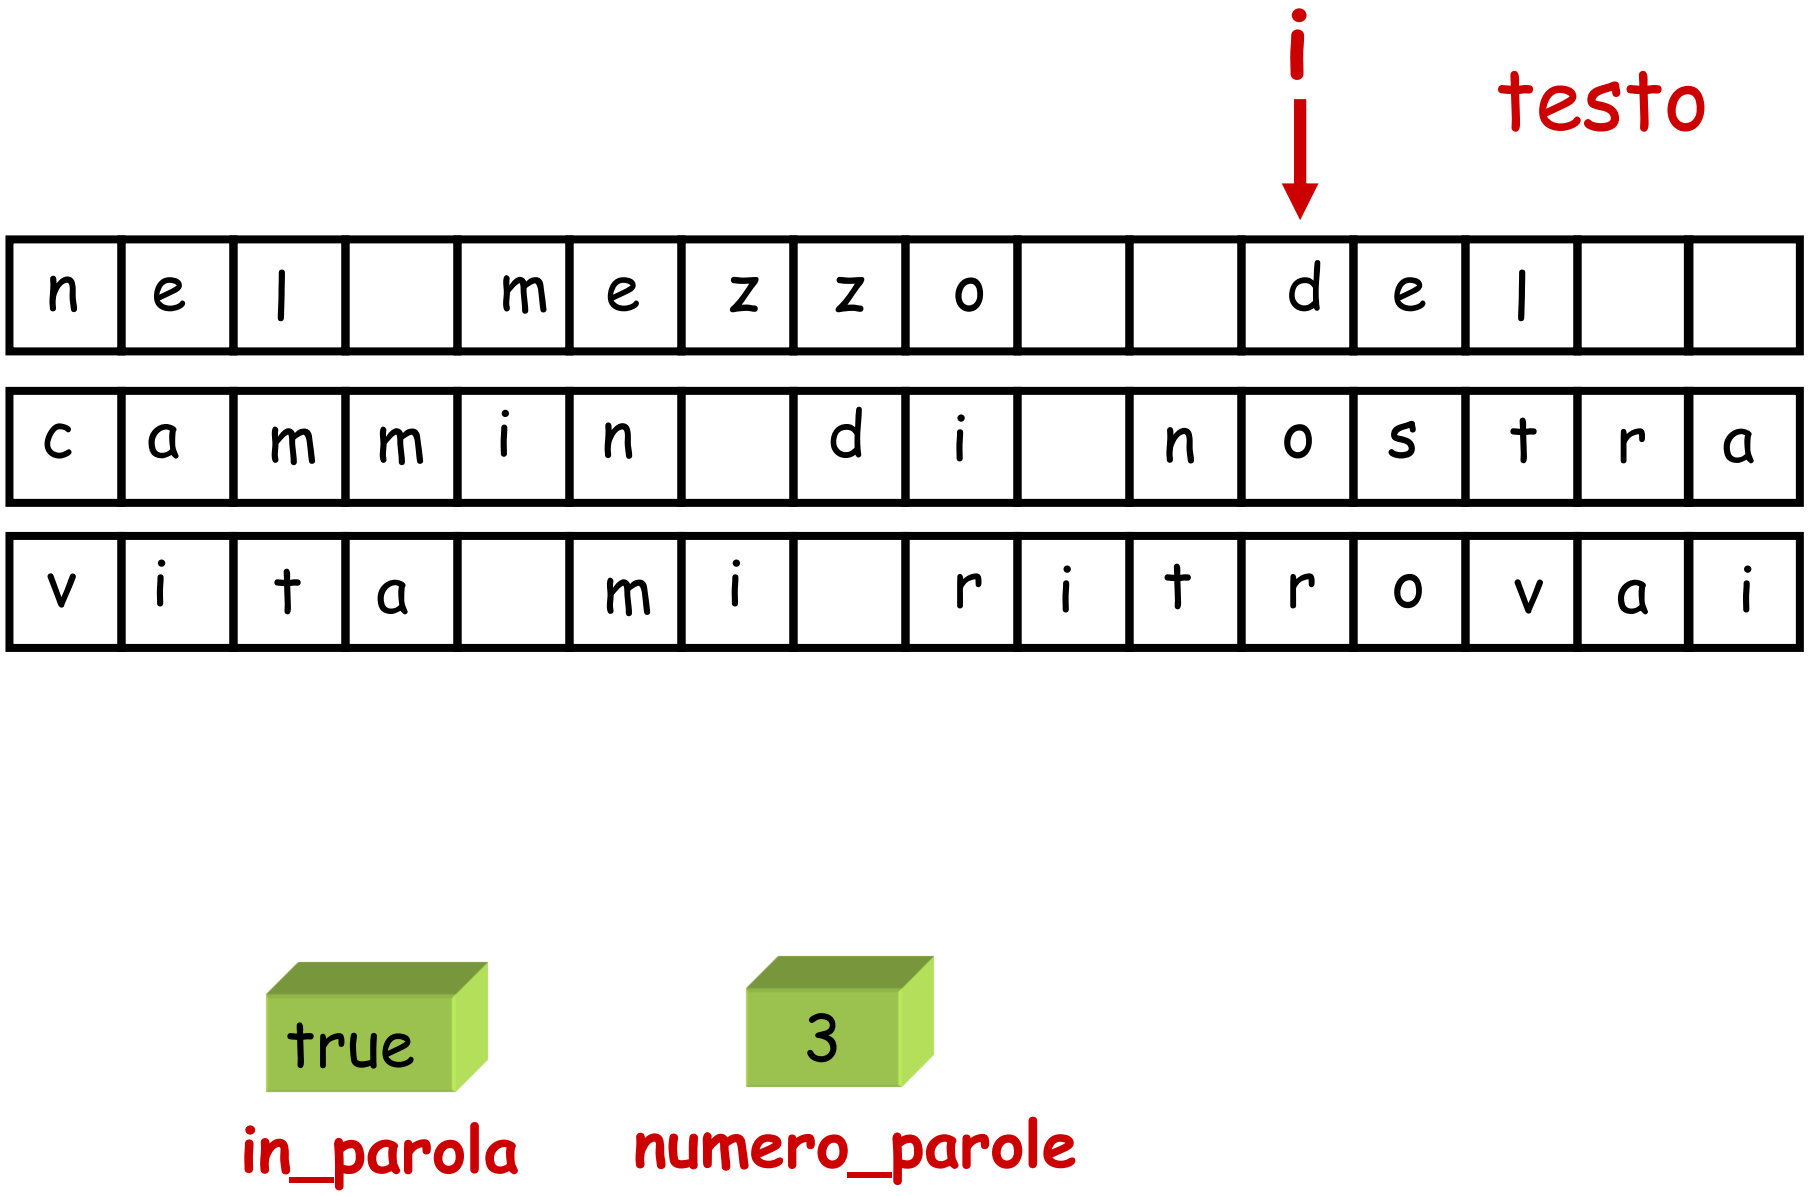
i
testo
n e l m e z z o d e l
c a m m i n d i n o s t r a
v i t a m i r i t r o v a i
true
3
in_parola
numero_parole

```
int conta_parole(char testo[],int m) {
 int i, numero_parole;
 logical in_parola;
 char c;
 numero_parole = 0;
 in_parola = false;
 for (i=0; i < m; i++) {
     c = testo[i] ;
     if (c = ' ' )
          { in_parola = false ; }
        else if  ( !in_parola ) {
                 in_parola = true ;
                 numero_parole = numero_parole + 1 ;
               }
 }
 return numero_parole ;
}
```

ATTENZIONE: da modificare in C

i-simo carattere della stringa **testo**

problema: (**string matching**)
calcolo del numero di volte in cui una stringa data (chiave) compare come sottostringa in un'altra stringa data (testo)

dati di input: la stringa chiave (array) chiave, la sua lunghezza (variabile n), la stringa testo (array testo), la sua lunghezza (variabile m)

dato di output: numero di occorrenze (variabile conta_chiave)

costrutto ripetitivo: 1+1 cicli innestati

operazione ripetuta (al generico passo i, ciclo **for** esterno)**:** confrontare la stringa chiave e la sottostringa (inizio i e lunghezza n) della stringa testo

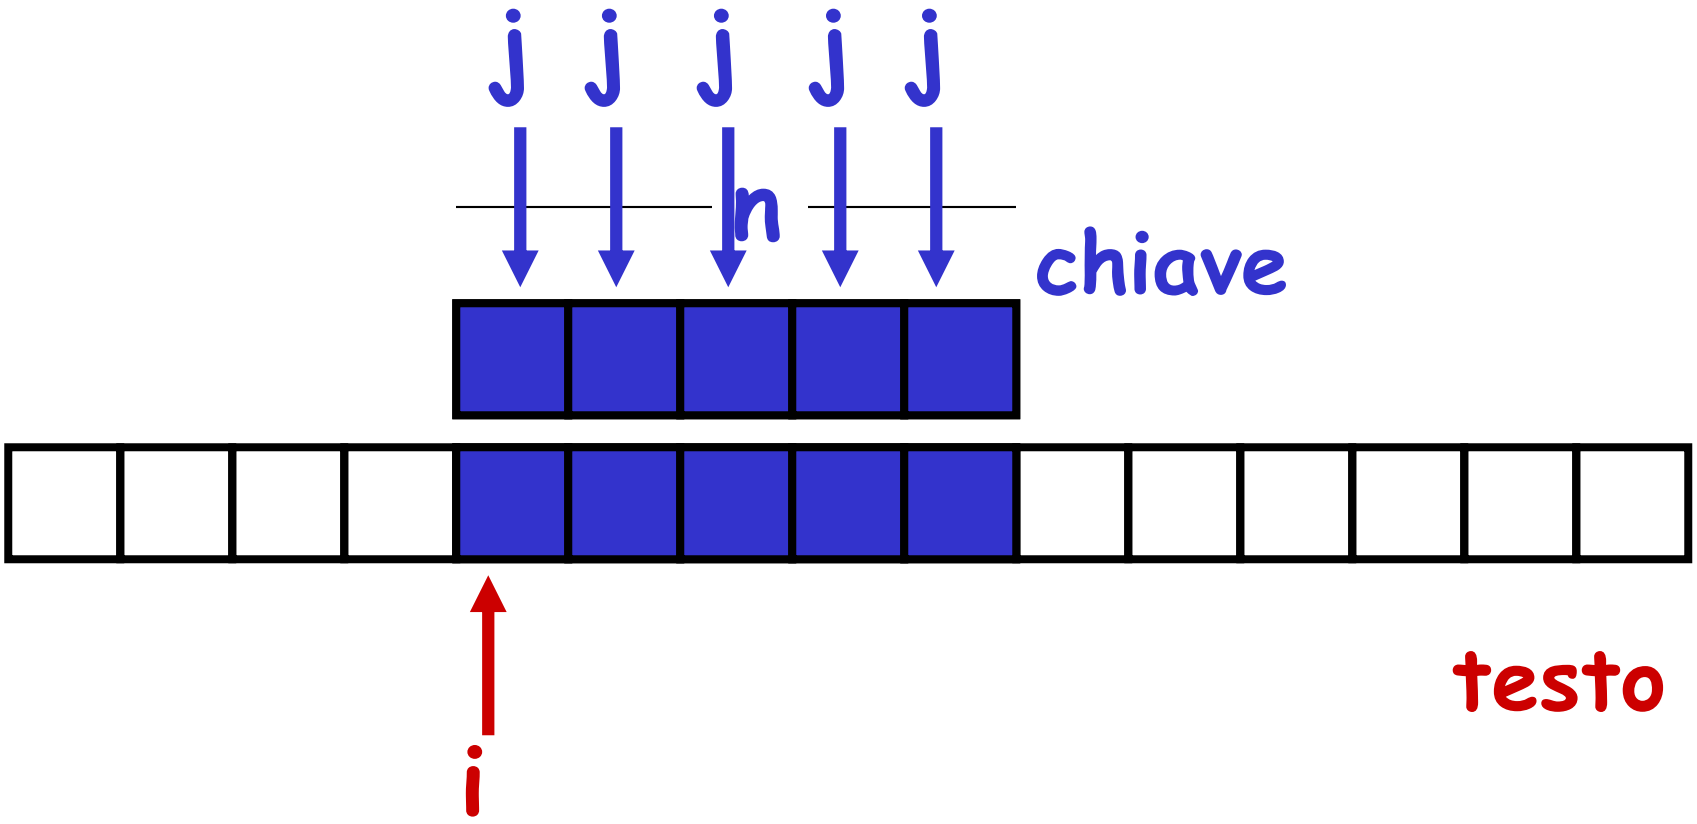
j j j j j
h
chiave
testo
i

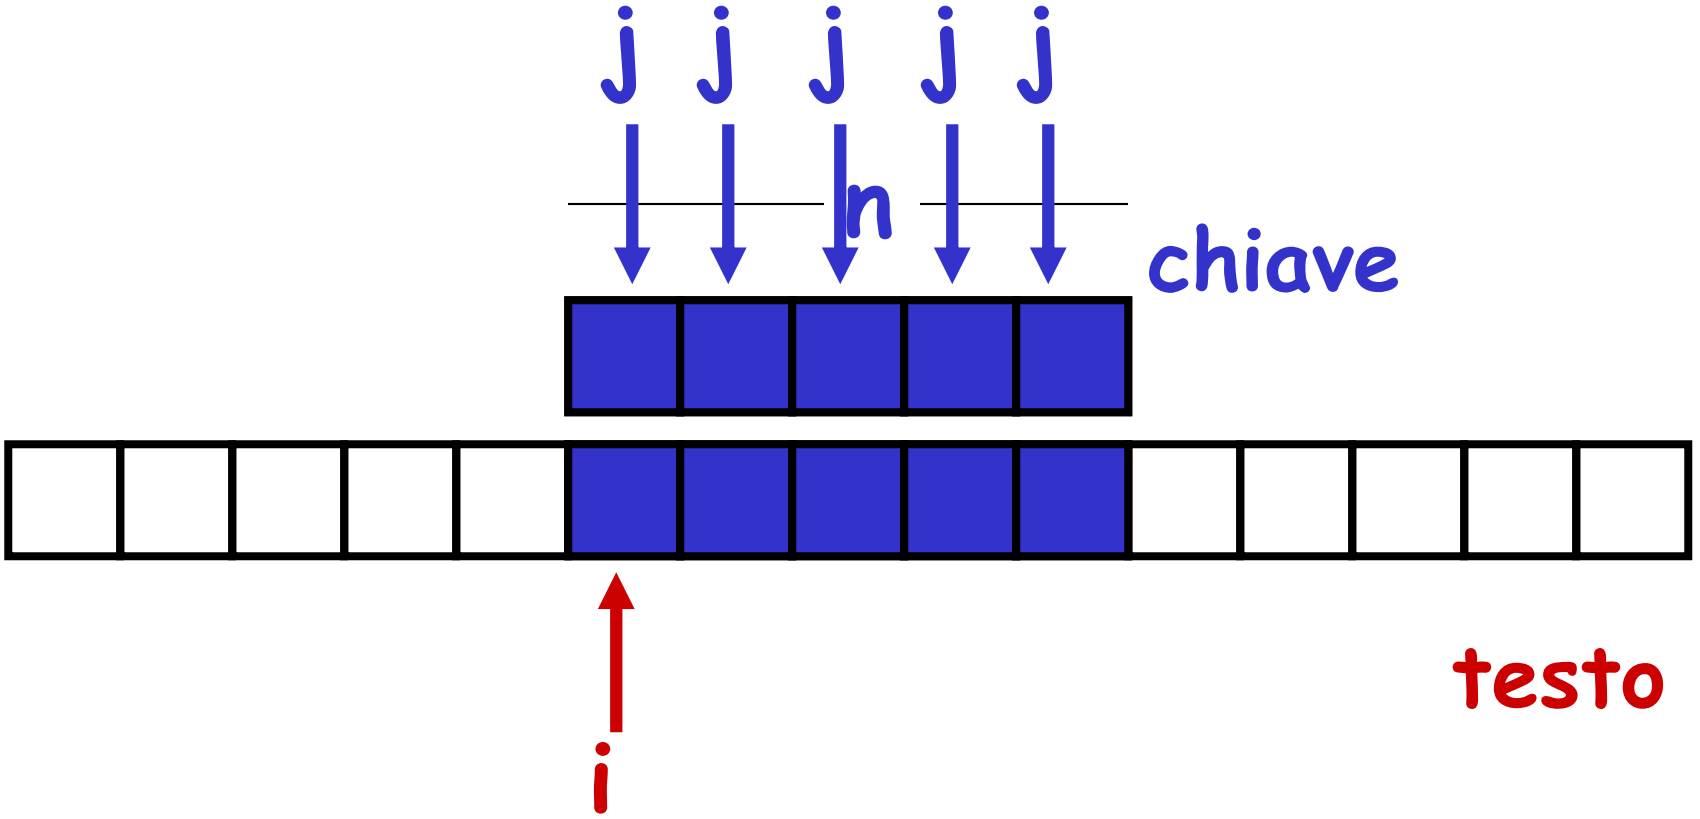
j j j j j
h
chiave
testo
i

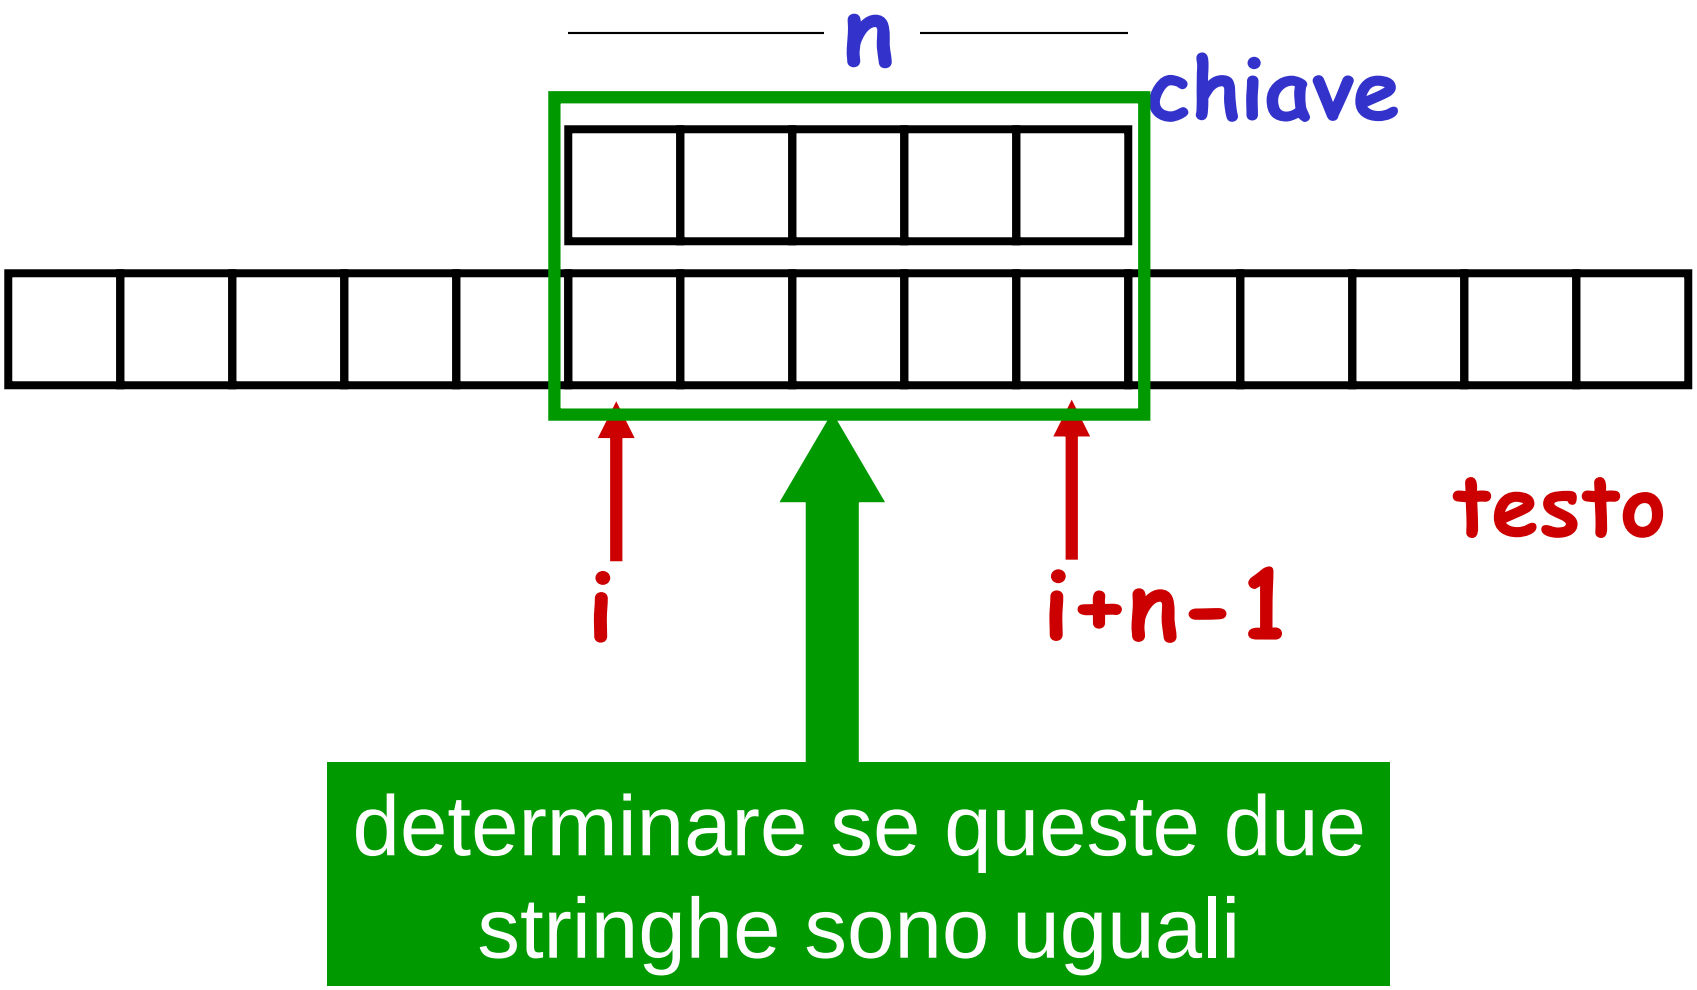
n
chiave
testo
i
i+n-1
determinare se queste due stringhe sono uguali

```
logical uguale_stringhe (char a[], char b[], int n) {
 int i;
 logical uguale;
  i = 0 ;
  uguale = true;
  while (uguale && i < n){
       if (a[(i] != b[i])
          { uguale = false;}
        i = i+1;
   }
  return uguale;
}
```

n confronti (al più)
(tra caratteri delle due stringhe)

è una variante della function **uguaglianza_array**

```
int string_matching(char chiave[], int n, char testo[],
                    int m) {
 int i, conta_chiave;
 conta_chiave = 0 ;
 for (i=0; i <= m-n; i++) {
     if (uguale_stringhe(chiave, testo+i, n) )
        { conta_chiave = conta_chiave + 1; }
  }
 return conta_chiave ;
}
```

sottostringa di inizio **i** della stringa **testo**

notazione di **porzione di array**

n*(m-n+1) confronti (al più)
(tra caratteri delle due stringhe)

problema:(**matching migliore**)
determinare la sottostringa di una stringa data (testo) che ha il maggior numero di caratteri (di ugual posto) uguali a quelli di un'altra stringa data (chiave)

dati di input: la stringa chiave (array chiave) la sua lunghezza (variabile n), la stringa testo (array testo), la sua lunghezza (variabile m)

dato di output: l'indice della sottostringa di matching migliore (variabile indice)

costrutto ripetitivo: 1+1 cicli **for** innestati

operazione ripetuta (al generico passo i, ciclo **for** esterno)**:** determinare il punteggio del *matching* tra la stringa chiave e la sottostringa (inizio i e lunghezza n) della stringa testo

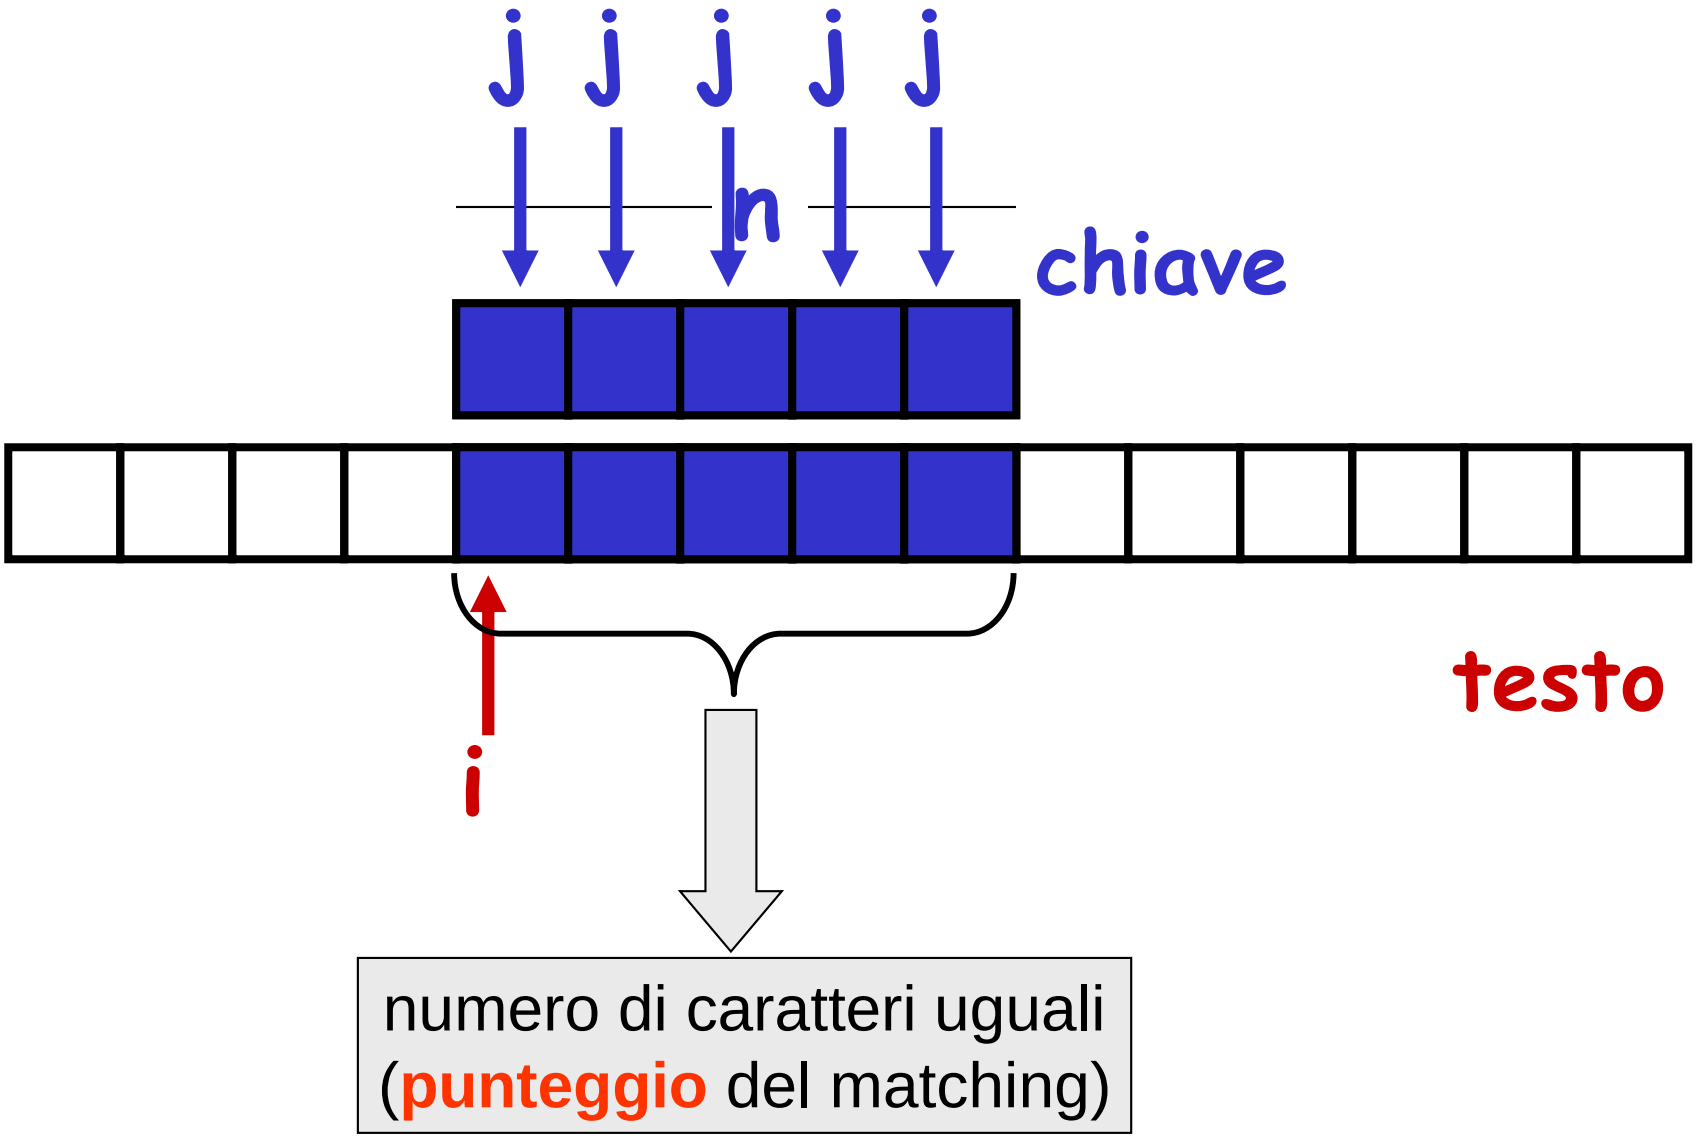
j j j j j
h
chiave
testo
i
numero di caratteri uguali
(punteggio del matching)

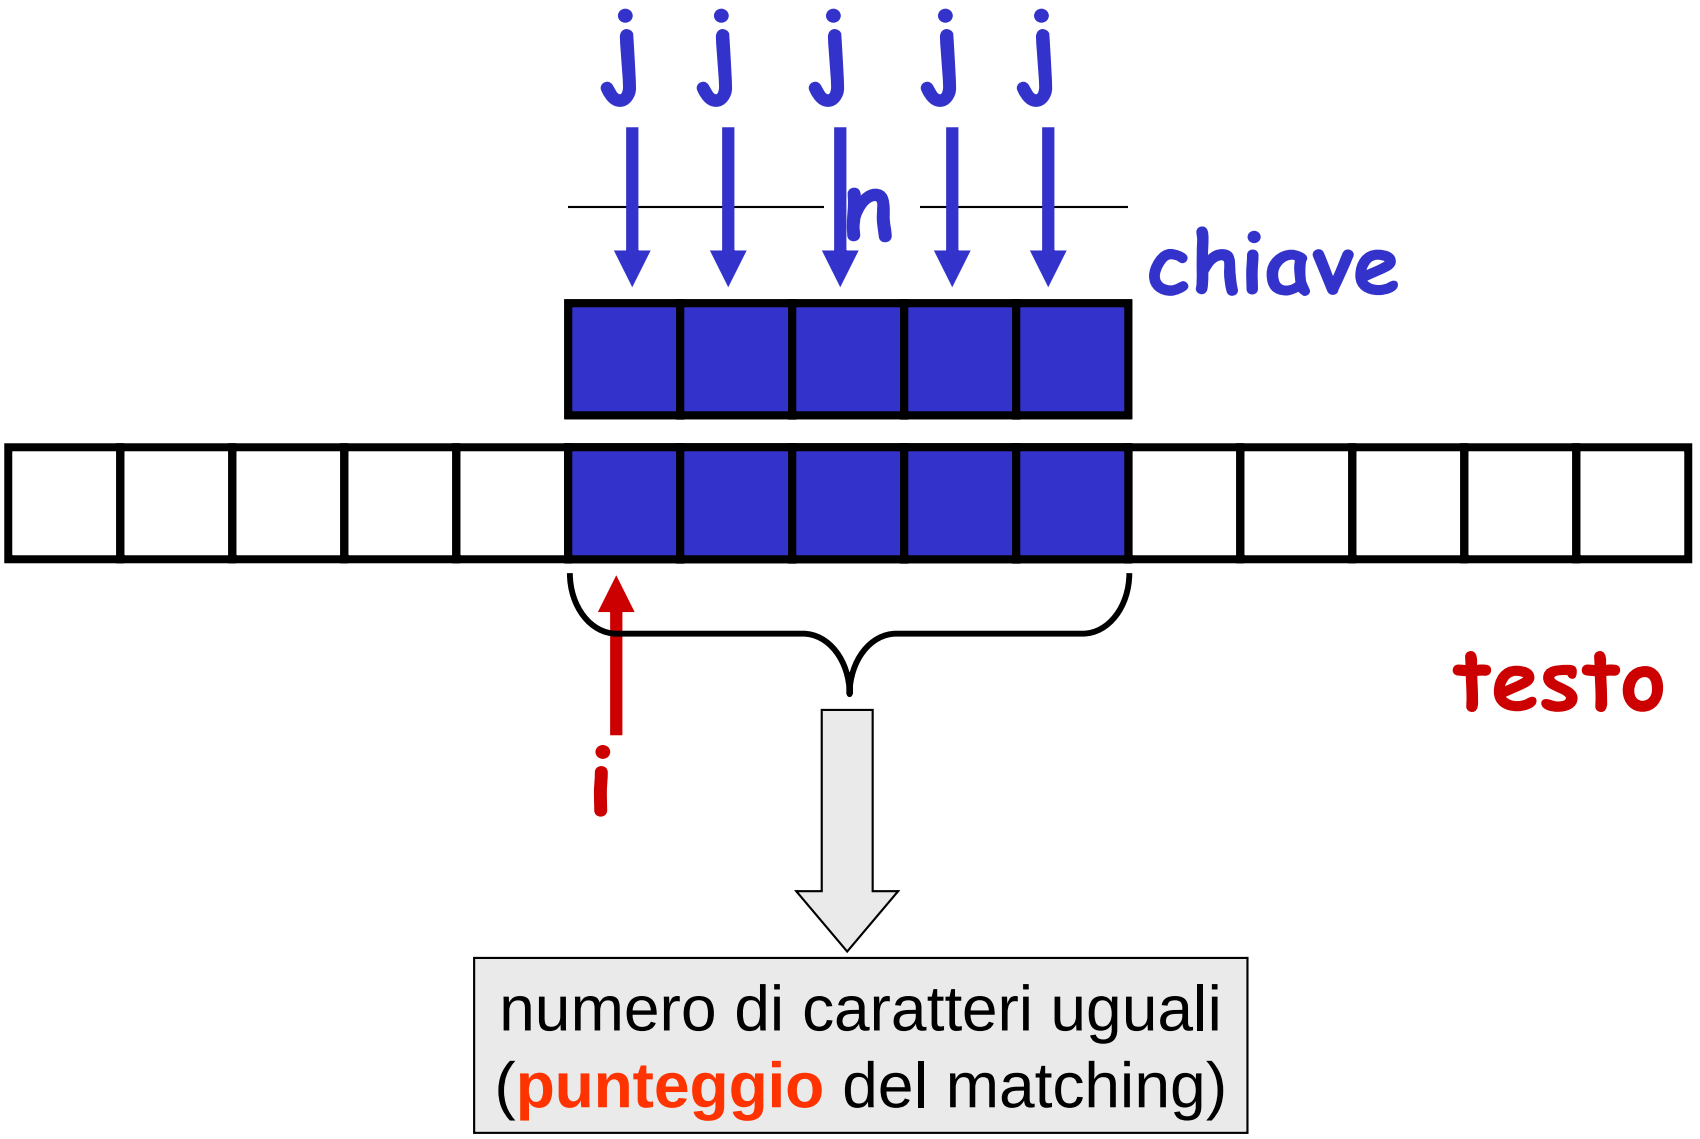
j j j j j
h
chiave
testo
i
numero di caratteri uguali
(punteggio del matching)

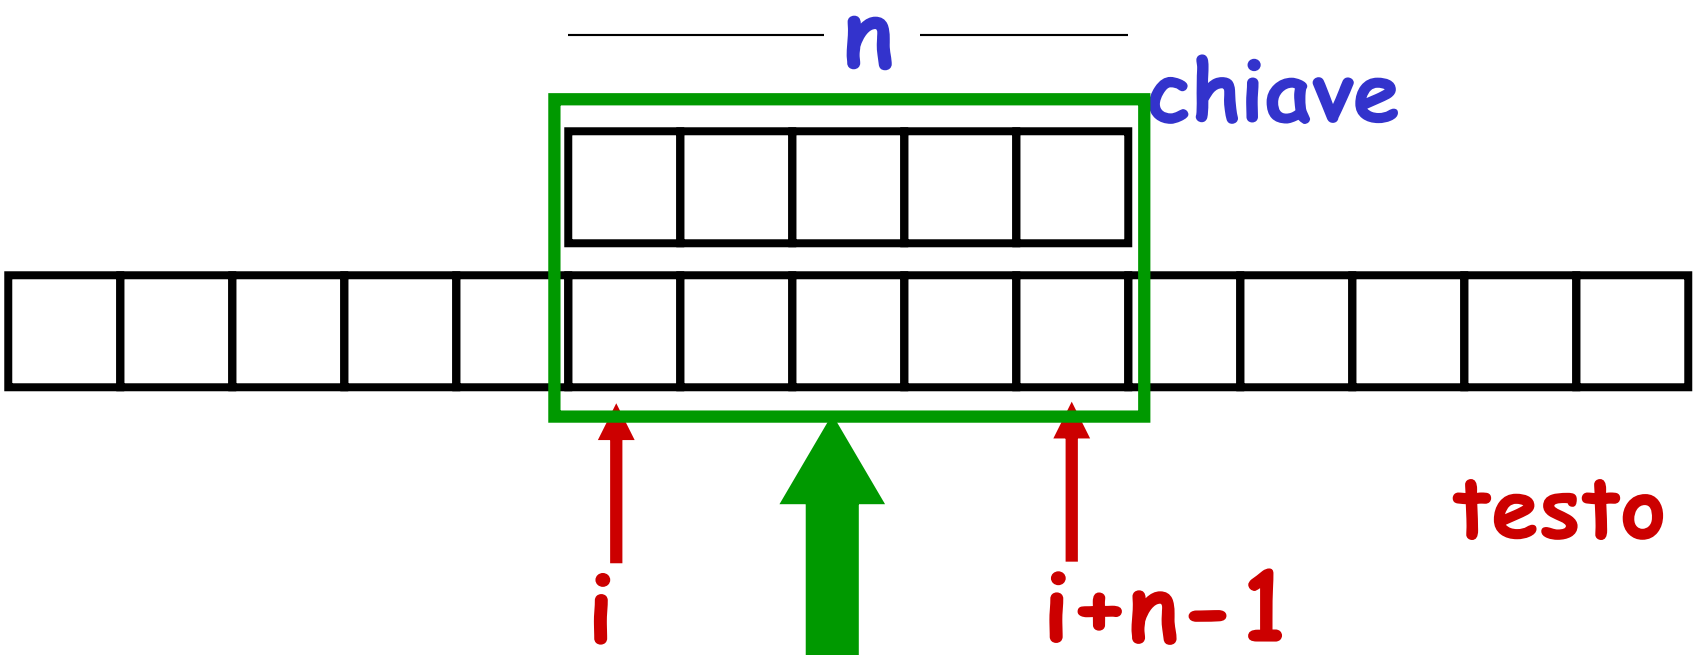

determinare il numero di caratteri uguali di queste due stringhe

```
int punteggio_matching(char a[], char b[], int n) {
 int i, n_caratteri_uguali;
 n_caratteri_uguali = 0;
 for (i=0; i < n; i++) {
      if (a[i] == b[i] )
        { n_caratteri_uguali = n_caratteri_uguali +1; }
  }
 return n_caratteri_uguali ;
}
```

n

confronti

(tra caratteri delle due stringhe)

```
int matching_migliore(char chiave[], int n, char testo[],
                      int m) {
 int i, punteggio_max, punteggio, indice;
 punteggio_max = 0 ;
 for (i=0; i <= m-n; i++) {
     punteggio = punteggio_matching(chiave,testo+i,n) ;
     if (punteggio > punteggio_max)
         {
           punteggio_max = punteggio ;
           indice = i ;
         }
   }
 return indice ;
}
```

sottostringa di inizio **i** della stringa **testo**

n*(m-n+1) confronti (tra caratteri delle due stringhe)