



Algoritmi e Strutture Dati

Ordinamento

Domenico Fabio Savo

Ordinamento

Problema: dato un insieme S di n oggetti presi da un dominio totalmente ordinato, ordinare S

Esempi: ordinare una lista di nomi alfabeticamente, o un insieme di numeri, o un insieme di compiti d'esame in base al cognome dello studente.

- Subroutine in molti problemi

E' possibile effettuare ricerche in array ordinati in tempo $O(\log n)$ (ricerca binaria)

Algoritmi e tempi tipici

- Numerosissimi algoritmi
- Tre tempi tipici: $O(n^2)$, $O(n \log n)$, $O(n)$

n	10	100	1000	10^6	10^9
$n \log_2 n$	~ 33	~ 665	$\sim 10^4$	$\sim 2 \cdot 10^7$	$\sim 3 \cdot 10^{10}$
n^2	100	10^4	10^6	10^{12}	10^{18}



Algoritmi di ordinamento



Approccio incrementale

Approccio incrementale:

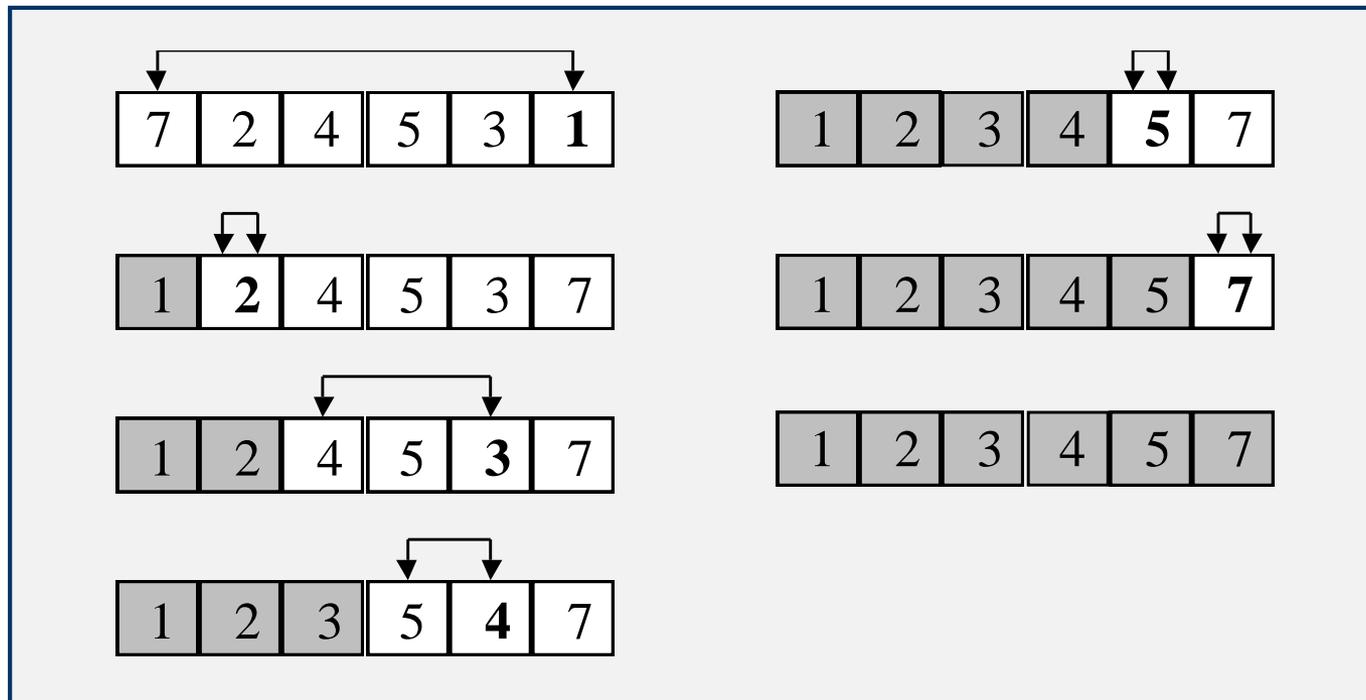
- Supponiamo che k elementi di un array di n siano già ordinati.
- Estendiamo l'ordinamento da k a $k+1$.

Come fare?

- **selectionSort**
- **insertionSort**

SelectionSort

Idea: estende l'ordinamento da k a $k+1$ elementi, scegliendo il minimo degli $n-k$ elementi non ancora ordinati e mettendolo in posizione $k+1$



SelectionSort: pseudocodice

Algoritmo: selectionSort(array S di dimensione n)

```
int m;
```

```
//Seleziono l'elemento più piccolo nella porzione di array non ordinata
```

```
//e lo aggiungo come più grande elemento alla porzione ordinata.
```

```
//La porzione di array non ordinata va (ad ogni ciclo) da k a n-1
```

```
for(int k = 0; k <= n-2; k++){
```

```
    m = k;
```

```
    //Seleziona il più piccolo elemento nella porzione di array da
```

```
    // ordinare. Tale elemento dovrà essere messo nella posizione k
```

```
    for(int j = k+1; j < n; j++){
```

```
        if(S[j] < S[m]) then m = j;
```

```
    }
```

```
    //Se l'elemento individuato si trova in una posizione m diversa da k
```

```
    //scambia il valore nella posizione m con quello nella posizione k
```

```
    if(m != k) then swap(S, m, k);
```

```
        //La funzione swap scambia tra loro i valori contenuti
```

```
        //nelle posizioni m e k dell'array S
```

```
    }
```

```
}
```

SelectionSort: analisi

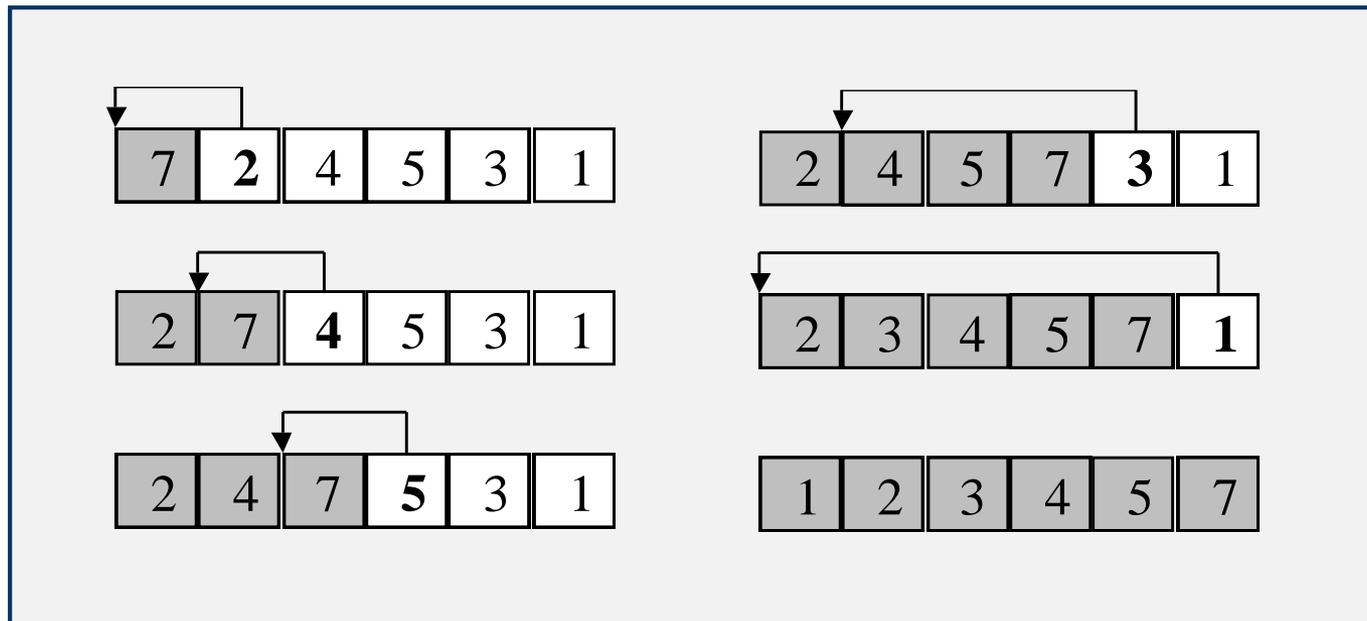
Individuare il k-esimo minimo costa tempo $O(n-k)$. Poichè il ciclo esterno viene eseguito $n-1$ volte, il numero totale di confronti è dato da:

$$\sum_{k=0}^{n-2} O(n-k) = O\left(\sum_{i=1}^{n-1} i\right) = \mathbf{O(n^2)}$$

usando il cambiamento di variabile $i = n-k$ e la serie aritmetica (vedere Paragrafo 17.2 in Appendice al libro).

InsertionSort

Idea: estende l'ordinamento da k a $k+1$ elementi, posizionando l'elemento $(k+1)$ -esimo nella posizione corretta rispetto ai primi k elementi



InsertionSort: pseudocodice

```
Algoritmo: insertionSort(array S di dimensione n)
//comincio ad ordinare gli elementi dal secondo elemento nell'array
for(int k = 1; k < n; k++){
    int elm = S[k]; //elem contiene l'elemento da riposizionare
    //cerco l'indice del più piccolo elemento più grande di elm tra
    //quelli che precedono elm in S
    int p = k;
    for(int j = 0; j < k; j++){
        if(S[j] > elm) then{
            p = j;
            break;}
    }
    //Se p precede k, sposto elem da k a p. Prima devo spostare tutti
    // gli elementi tra p e k-1 di una posizione in avanti.
    if(p < k) then {
        for(int i = k; i >= p+1; i--){
            S[i] = S[i-1]; }
        S[p] = elm; //ora che c'è spazio copio elm nella posizione p.
    }
}
```

InsertionSort: analisi

L'inserimento del k-esimo elemento nella posizione corretta rispetto ai primi k richiede tempo $O(k)$ nel caso peggiore

In totale, il tempo di esecuzione è pertanto:

$$O\left(\sum_{k=1}^{n-1} k\right) = O(n^2)$$

usando la serie aritmetica



BubbleSort

Esegue una serie di scansioni dell'array:

- In ogni scansione confronta coppie di elementi adiacenti, scambiandoli se non sono nell'ordine corretto
- Dopo una scansione in cui non viene effettuato nessuno scambio l'array è ordinato
- Dopo la k -esima scansione, i k elementi più grandi sono correttamente ordinati ed occupano le k posizioni più a destra.

BubbleSort: esempio di esecuzione

(1)

7	2	4	5	3	1
---	---	---	---	---	---

2 7
4 7
5 7
3 7
1 7

(2)

2	4	5	3	1	7
---	---	---	---	---	---

2 4
4 5
3 5
1 5

2	4	3	1	5	7
---	---	---	---	---	---

(3)

2	4	3	1	5	7
---	---	---	---	---	---

2 4
3 4
1 4

(4)

2	3	1	4	5	7
---	---	---	---	---	---

2 3
1 3

(5)

2	1	3	4	5	7
---	---	---	---	---	---

1 2

1	2	3	4	5	7
---	---	---	---	---	---

BubbleSort: pseudocodice

Algoritmo: bubbleSort(array S di dimensione n)

```
boolean scambi = false;
for(int i = 0; i < n; i++){
    scambi = false;
    //Confronto tra loro tutte le coppie tra n-i fino
    //all'inizio dell'array. Dati due elementi, se non sono
    //ordinati allora scambio la loro posizione
    for(int j = 1; j < n-i; j++){
        if(S[j-1] > S[j]) then {
            swap(S, j-1, j);
            scambi = true;
        }
    }
    if(not scambi) then break;
}
```



BubbleSort: analisi

Dato che dopo la k -esima scansione, i k elementi più grandi sono correttamente ordinati, effettueremo al più $(n-1)$ cicli. Nel caso peggiore, alla k -esima scansione vengono eseguito $(n-k)$ confronti. Pertanto:

$$\sum_{k=1}^{n-1} O(n-k) = O\left(\sum_{j=1}^{n-1} j\right) = \mathbf{O(n^2)}$$

usando il cambiamento di variabile $j = n-i$ e la serie aritmetica (vedere Paragrafo 17.2 in Appendice al libro).



$O(n^2)$ non è un buon risultato: stiamo facendo
tutti i confronti possibili!

Possiamo fare di meglio?



HeapSort

- Utilizza lo stesso approccio incrementale utilizzato nel **selectionSort**, ma esegue nel caso peggiore un numero inferiore di confronti grazie all'uso di una struttura dati che individua l'elemento **più grande** in tempo $O(\log n)$.
- **NOTA:** eseguiamo l'ordinamento a partire dall'elemento più grande (a differenza del selectionSort dove cominciavamo dall'elemento più piccolo).
- **Struttura dati heap:** associata ad un insieme S di elementi è un **albero binario** con le seguenti proprietà:
 - 1) È completo fino al penultimo livello (un albero è completo se tutte le foglie sono allo stesso livello)
 - 2) gli elementi di S sono memorizzati nei nodi dell'albero. Ogni nodo v contiene un solo elemento di S che indichiamo con **chiave(v)**.
 - 3) Vale la seguente regola: il valore dell'elemento in un nodo è sempre maggiore o uguale al valore degli elementi dei suoi figli.

HeapSort: proprietà di ordinamento

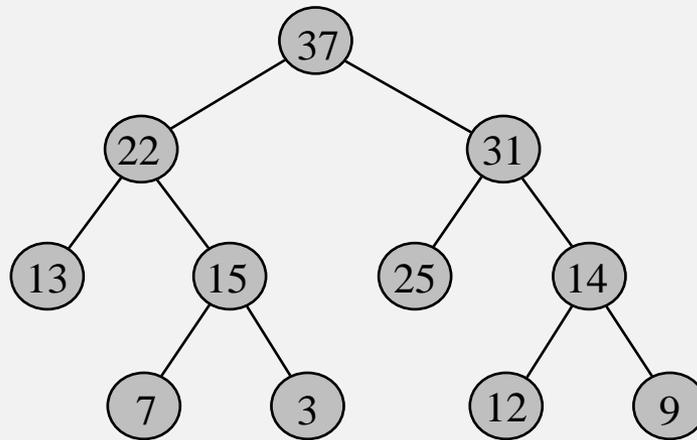
Se dato un nodo v , denotiamo rispettivamente con $\mathbf{sin}(v)$ e $\mathbf{des}(v)$ il figlio sinistro e destro del nodo v , possiamo sintetizzare la **proprietà 3)** di un Heap nel seguente modo:

$$\mathbf{chiave}(v) \geq \mathbf{chiave}(\mathbf{sin}(v))$$

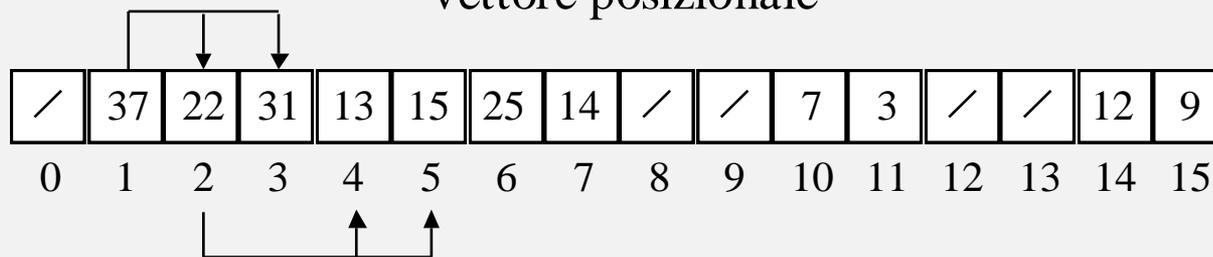
$$\mathbf{chiave}(v) \geq \mathbf{chiave}(\mathbf{des}(v))$$

Struttura dati heap

Rappresentazione ad albero e con vettore posizionale



vettore posizionale

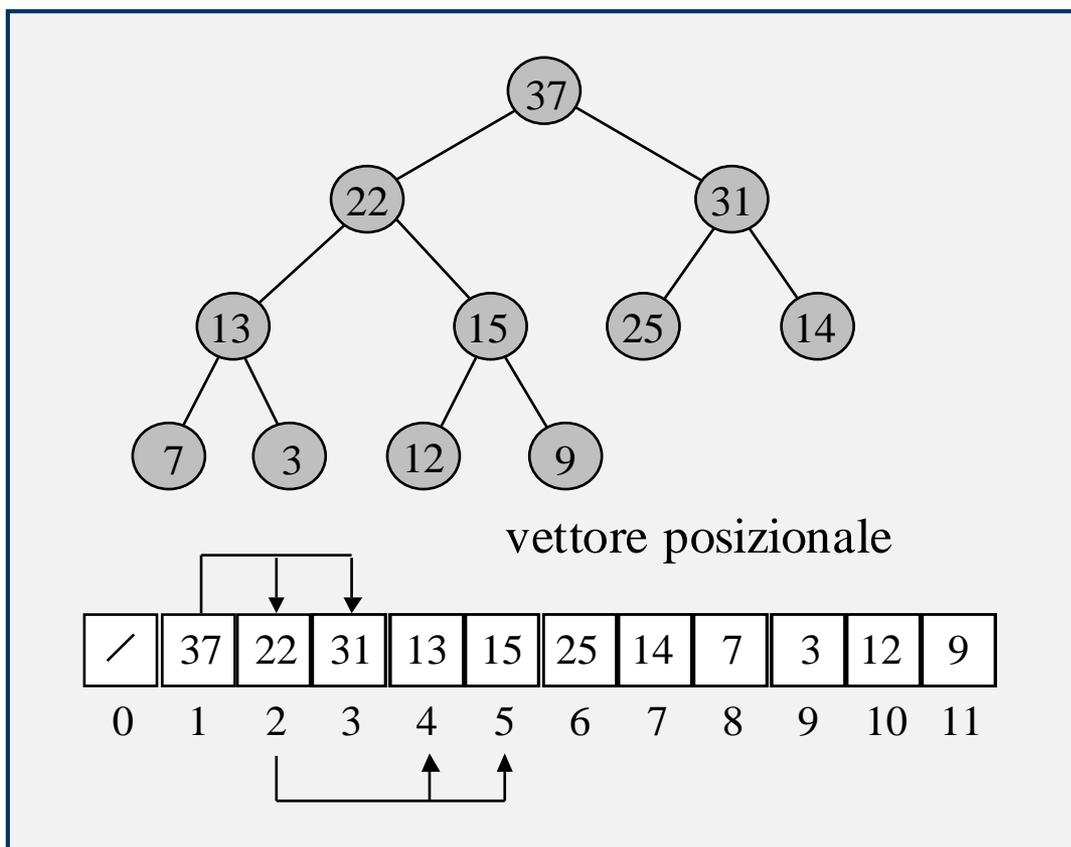


$$\text{sin}(i) = 2i$$

$$\text{des}(i) = 2i+1$$

Heap con struttura rafforzata

Le foglie nell'ultimo livello sono compattate a sinistra



Il vettore
posizionale ha
esattamente
dimensione n



Proprietà salienti degli heap

- 1) Il **massimo** è contenuto nella radice
- 2) L'albero ha altezza **$O(\log n)$**
- 3) Gli heap con struttura rafforzata possono essere rappresentati in un array di dimensione pari a **n**

La procedura fixHeap

Se tutti i nodi di H tranne v soddisfano la proprietà di ordinamento a heap, possiamo ripristinarla come segue:

```
Algoritmo fixHeap(nodo  $v$ , heap  $H$ )  
  if ( $v$  è una foglia) then return  
  else  
    sia  $u$  il figlio di  $v$  con chiave massima  
    if (chiave( $v$ ) < chiave( $u$ )) then  
      scambia chiave( $v$ ) e chiave( $u$ )  
      fixHeap( $u$ ,  $H$ )
```

Tempo di esecuzione: $O(\log n)$

Estrazione del massimo

Dato un heap H vogliamo individuare il massimo valore in esso contenuto e rimuoverlo da H . **Come fare?**

- Sappiamo che il massimo è sempre contenuto nella radice!
- Con quale valore devo però sostituire il valore nella radice affinché la proprietà di ordinamento dell'heap sia ancora valida?

getMax(heap H) \rightarrow elem e

1. elem $e \leftarrow$ chiave(radice di H);
2. copio nella radice la chiave contenuta nella la foglia più a destra dell'ultimo livello;
3. rimuovo la foglia;
4. ripristino la proprietà di ordinamento dell'heap richiamando **fixHeap** sulla radice;
5. **return e** ;

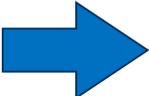
Tempo di esecuzione: **$O(\log n)$**

Costruzione dell'heap

Costruisco un albero binario usando gli elementi del vettore S e poi lo ordino usando il seguente algoritmo ricorsivo basato sul *divide et impera*.

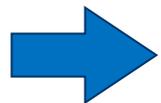
```
Algoritmo heapify(albero H)
  if (H è vuoto) then return
  else
    heapify(sottoalbero sinistro di H)
    heapify(sottoalbero destro di H)
    fixHeap(radice di H, H)
```

Tempo di esecuzione: $T(n) = 2T(n/2) + O(\log n)$

 $T(n) = O(n)$ dal *Teorema Master*

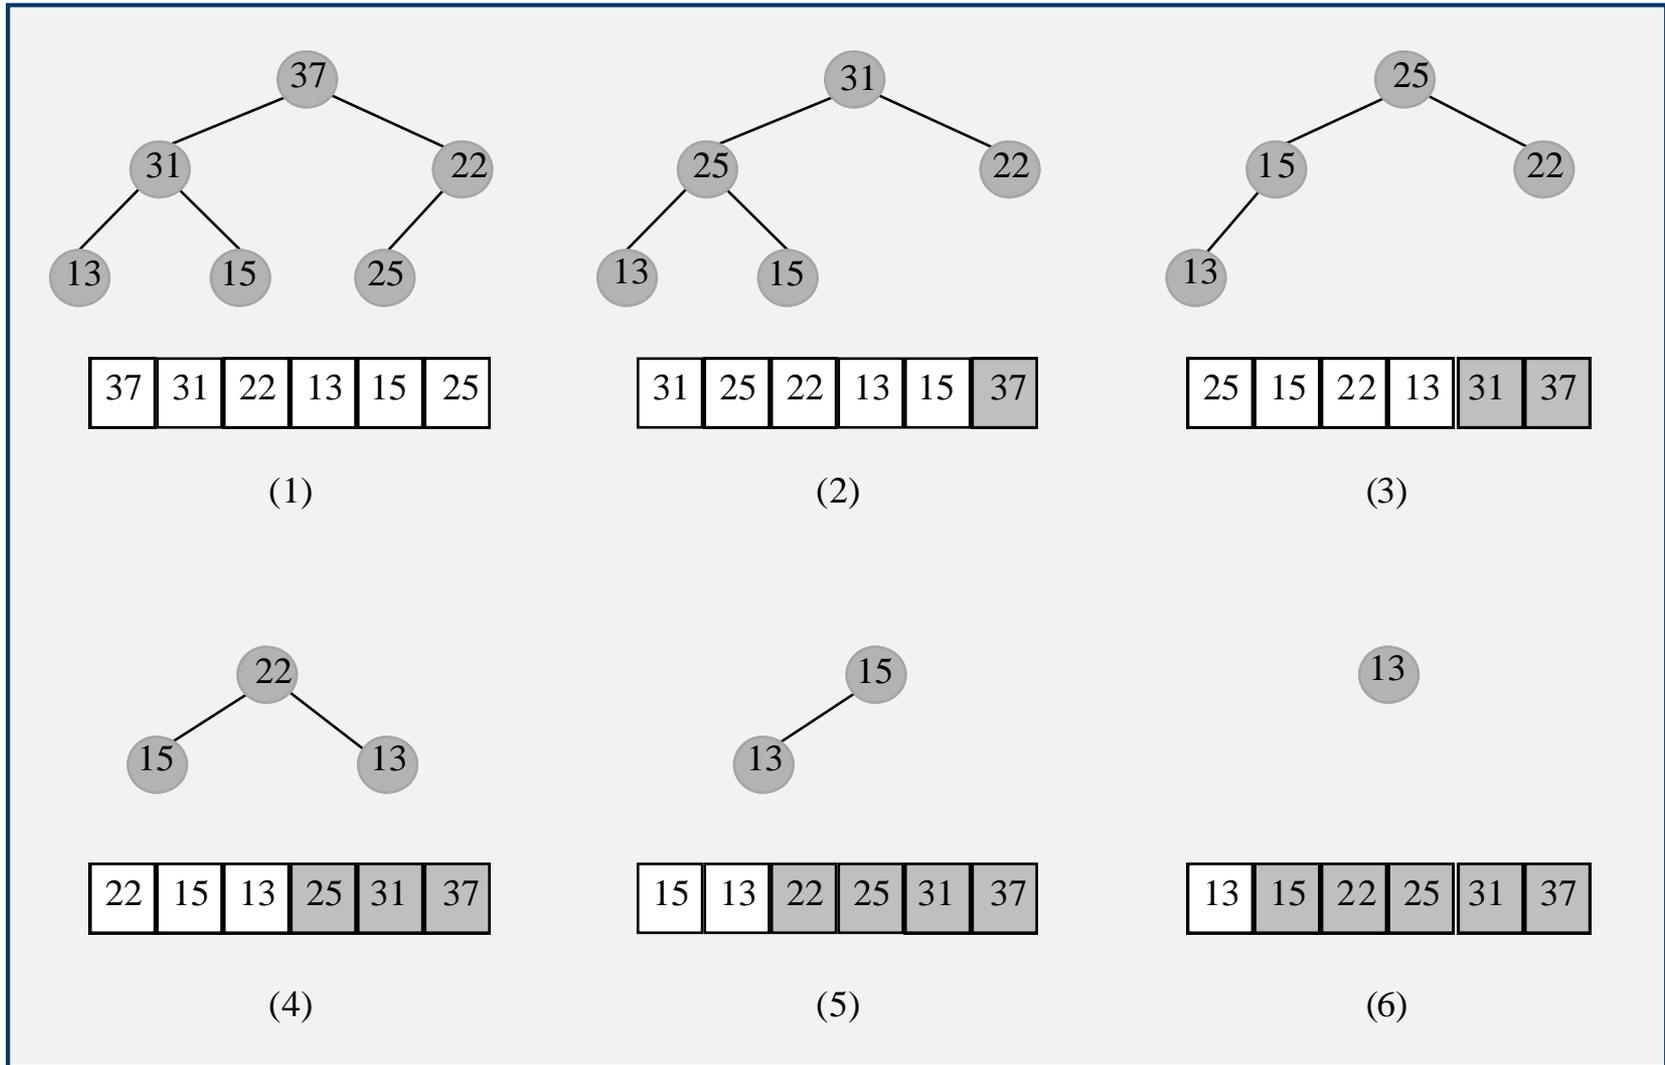
L'algoritmo HeapSort

```
Algoritmo heapSort(array S di dimensione n)
if (S è vuoto) then return S;
else {
  - costruisci un albero binario H con gli elementi di S;
  - ordinalo usando heapyfy(H); //costa O(n)
  - crea un coda C vuota.
  - while(H non è vuoto){           //cicla n volte
      C.enqueue(getMax(H));         //getMax ha costo O(log n)
  - copia gli elementi di C in S nel giusto ordine
  - return S
  }
```



ordina in tempo **$O(n \log n)$**

HeapSort: esempio di esecuzione



MergeSort (1/2)

- Basato sulla tecnica *divide et impera*:
- Vediamo prima il passo *Impera*: dati due **array ordinati** A e B fonderli a creare un nuovo **array ordinato**:

merge(array A ordinato, array B ordinato) → array X ordinato

1. Sia X un nuovo array vuoto;
2. estrai ripetutamente il minimo di A e B e copialo in X, finché A oppure B non diventa vuoto;
3. copia gli elementi dell'array non vuoto alla fine di X;
4. Restituisci X;

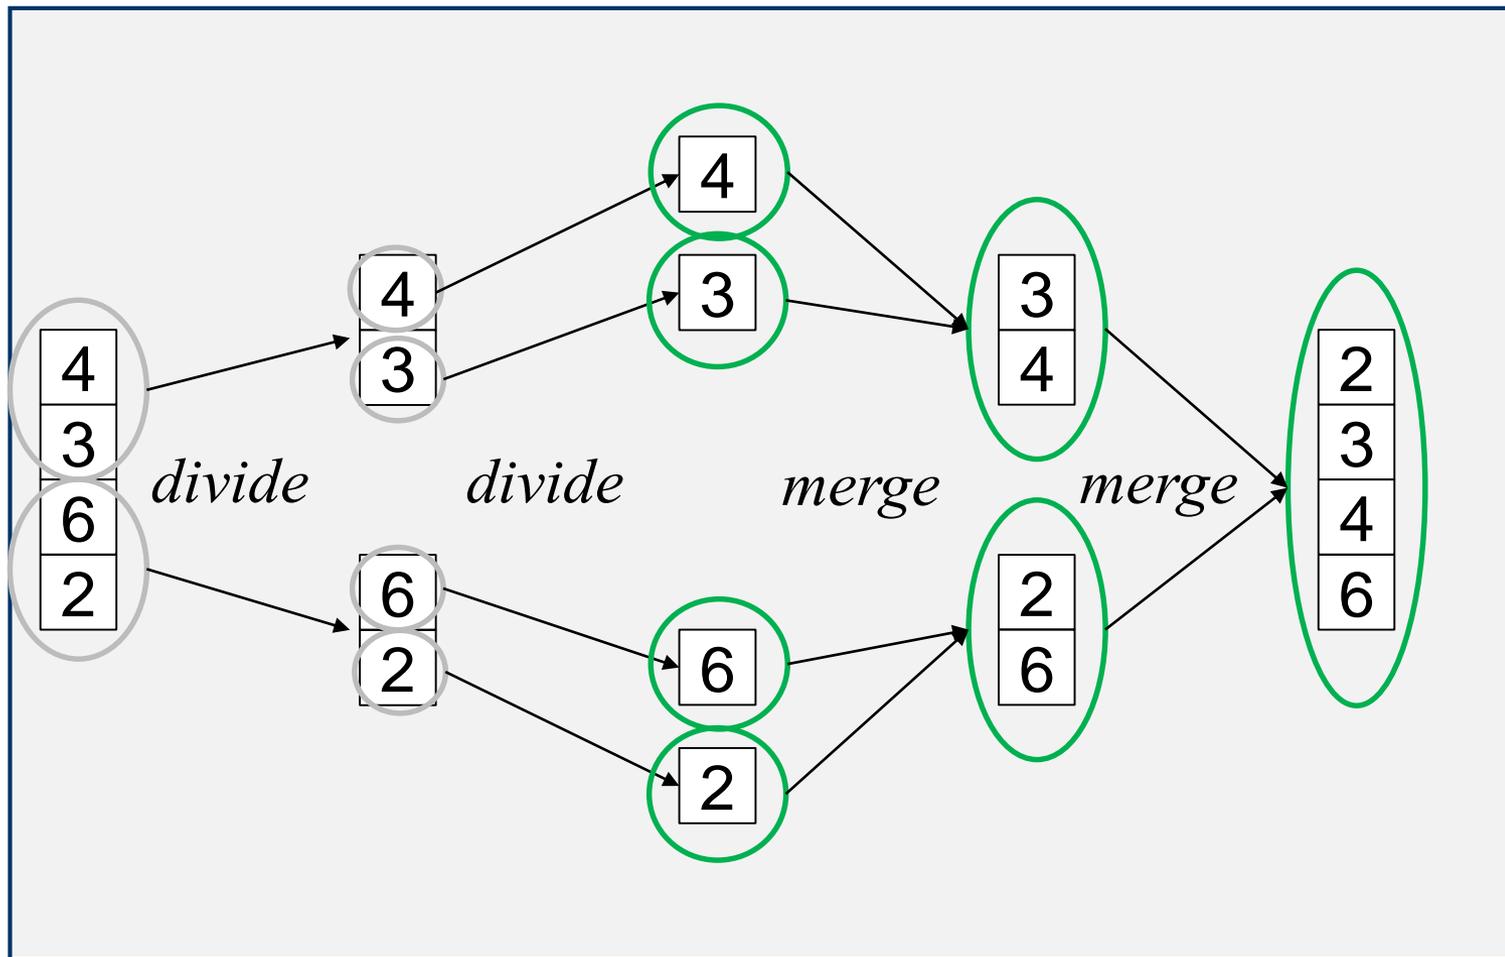
La procedura **merge(A,B)** esegue al più **|A| + |B| + 1** confronti

MergeSort (2/2)

Passo *divide*: sappiamo come fondere due array ordinati, quindi possiamo dividere l'array in due parti, ordinarli ricorsivamente e poi fonderli nuovamente.

```
Algoritmo mergeSort(array S) → array
if (S è vuoto) then return S;
else { if(|S| = 1) then return S
      else {
          S1 ← mergeSort(metà sinistra di S)
          S2 ← mergeSort(metà destra di S)
          return merge(S1, S2)
      }
}
```

MergeSort: esempio di esecuzione



Tempo di esecuzione

- Il numero di confronti del MergeSort è descritto dalla seguente relazione di ricorrenza:

$$T(n) = T(n/2) + O(n)$$

- Usando il *Teorema Master* si ottiene:

$$T(n) = \mathbf{O(n \log n)}$$

(stesso costo dell'HeapSort!)

QuickSort

Anche il QuickSort adotta la tecnica del *divide et impera*:

Sia A un array:

- 1 ***Divide***: scegli un elemento x di A (chiameremo x *perno*) e partiziona gli elementi di A in due sotto-array in cui il primo contiene tutti gli elementi di A **più piccoli o uguali** ad x , ed il secondo tutti gli elementi di A **strettamente maggiori** di x .
- 2 Risolvi i due sottoproblemi ricorsivamente.
- 3 ***Impera***: restituisci la concatenazione dei due sotto-array ordinati

A differenza del MergeSort il passo *divide* è complesso, mentre il passo *impera* (che qui consiste nella semplice fusione di due array) è molto semplice

QuickSort: pseudocodice

```
Algoritmo quickSort(array A)
scegli un elemento x di A;
Partizione A rispetto ad x calcolando i due array:
    A1 = { y ∈ A : y ≤ x }
    A2 = { y ∈ A : y > x }
if (|A1| > 1) then quickSort(A1);
if (|A2| > 1) then quickSort(A2);
copia la concatenazione di A1 e A2 in A
```

Calcolare le due partizioni richiede **O(n)** confronti

QuickSort: analisi nel caso peggiore

- Nel caso peggiore, il perno scelto ad ogni passo è il minimo o il massimo degli elementi nell'array.
- Il numero di confronti nel caso peggiore è descritto dalla seguente relazione di ricorrenza:

$$C(n) = C(n-1) + O(n)$$

- Svolgendo per iterazione si ottiene

$$C(n) = O(n^2)$$

QuickSort: randomizzazione

- Possiamo evitare il caso peggiore scegliendo come perno un elemento dell'array A "a caso".
- Poiché ogni elemento ha la stessa probabilità, pari a $1/n$, di essere scelto come perno, il numero di confronti nel caso atteso è:

$$C(n) = \sum_{a=0}^{n-1} \frac{1}{n} \left[n-1 + C(a) + C(n-a-1) \right] = n-1 + \sum_{a=0}^{n-1} \frac{2}{n} C(a)$$

dove a e $(n-a-1)$ sono le dimensioni dei sottoproblemi risolti ricorsivamente

QuickSort: analisi nel caso medio

La relazione di ricorrenza: $C(n) = n - 1 + \sum_{a=0}^{n-1} \frac{2}{n} C(a)$

ha soluzione $C(n) \leq 2 n \log n$, pertanto il numero di confronti atteso è **$O(n \log n)$**

Quindi il *quickSort* è meno efficiente nel caso peggiore del *mergeSort* e del *heapSort* e per evitare il caso peggiore lo rendiamo "*randomizzato*".

Il *quickSort* è però molto utilizzato in quanto esistono sue varianti ottimizzate estremamente veloci.



Utilizzando algoritmi come il *mergeSort* e l'*heapSort* possiamo ordinare un insieme di elementi con un numero di confronti pari a **$O(n \log n)$** .

Possiamo fare di meglio?

Lower bound

- Dimostrazione (matematica) che non possiamo andare più veloci di una certa quantità.
- Più precisamente, ogni algoritmo all'interno di un certo **modello di calcolo** deve avere tempo di esecuzione almeno pari a quella quantità.
- Non significa necessariamente che non è possibile fare di meglio, infatti potrebbe essere possibile fare di meglio al di fuori di quel modello di calcolo.

Lower bound per l'ordinamento

- Delimitazione inferiore: quantità di risorsa necessaria per risolvere un determinato problema.
- Dimostrare che $\Omega(n \log n)$ è **lower bound** al numero di confronti richiesti per ordinare n oggetti.

Come?

Dobbiamo dimostrare che tutti gli algoritmi richiedono almeno $\Omega(n \log n)$ confronti!



Modello basato sui confronti

- In questo modello, per ordinare è possibile usare solo confronti tra oggetti
- Primitive quali operazioni aritmetiche (somme o prodotti), logiche (and e or), o altro (shift) sono proibite.
- Sufficientemente generale per catturare le proprietà degli algoritmi più noti

Come dimostrare il lower bound

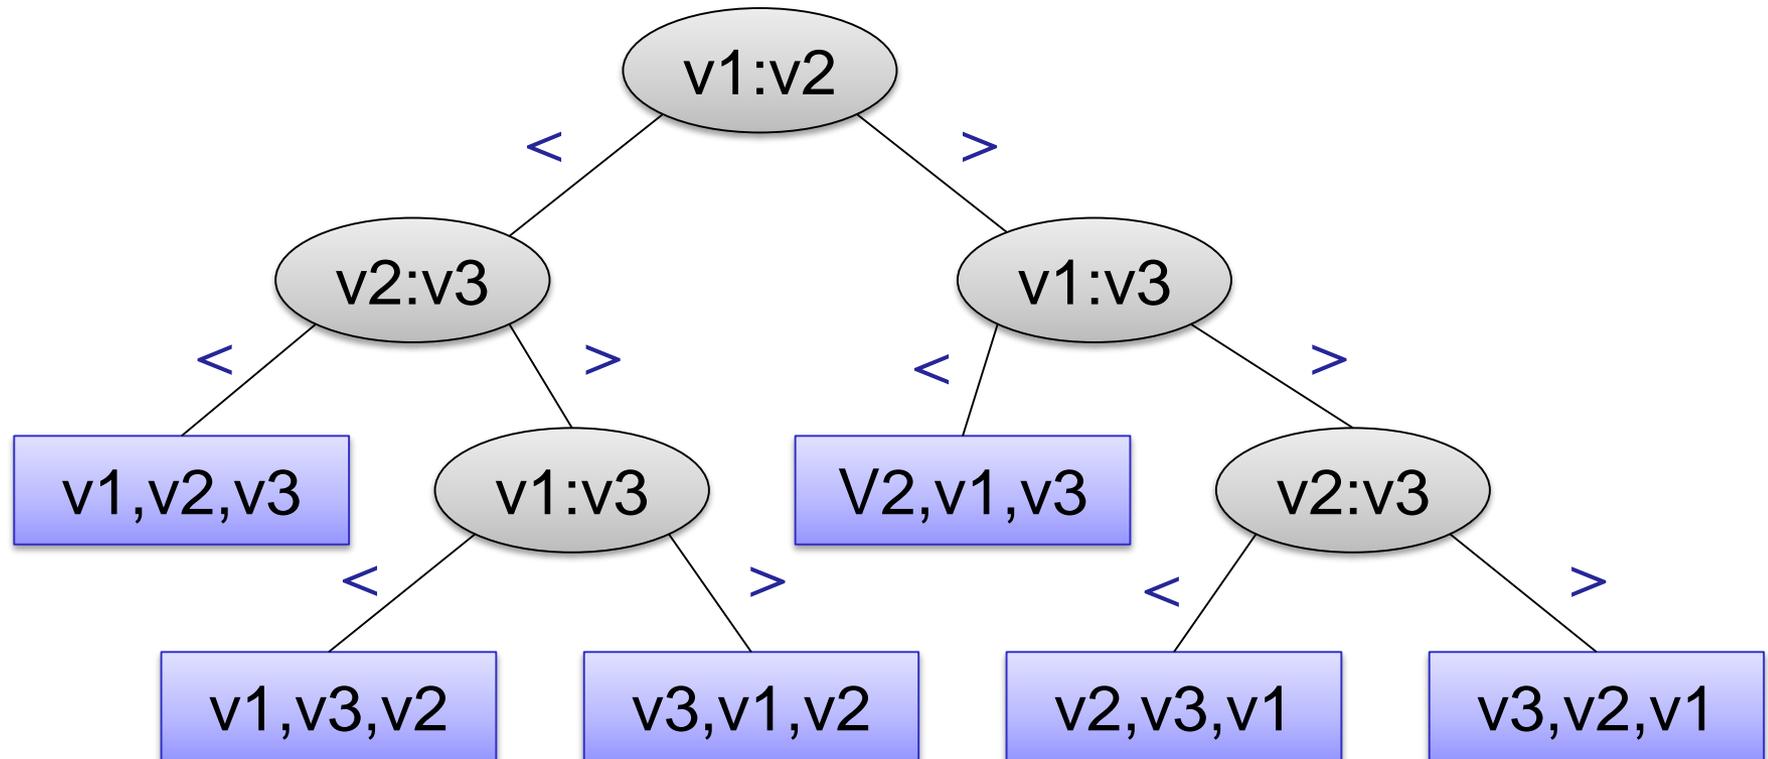
- Consideriamo un qualsiasi algoritmo **A**, che ordina solo mediante confronti.
- Non abbiamo assolutamente idea di come funziona **A**!
- Ciò nonostante, dimostreremo che **A** deve eseguire almeno $\Omega(n \log n)$ confronti per ordinare un insieme di elementi con cardinalità **n**.
- Dato che l'unica ipotesi su **A** è che ordini mediante confronti, il **lower bound** sarà valido per tutti gli algoritmi basati su confronti!

Come dimostrare il lower bound

- Osservazione fondamentale: tutti gli algoritmi devono confrontare elementi
- Dati due valori v_1 e v_2 , i casi possibili sono tre:
 $v_1 < v_2$, $v_2 > v_1$, oppure $v_1 = v_2$.
- Per semplicità assumeremo che tutti gli elementi sono tra loro diversi
- Si assume dunque che tutti i confronti abbiano la forma $v_1 < v_2$, e il risultato del confronto sia *vero* o *falso*

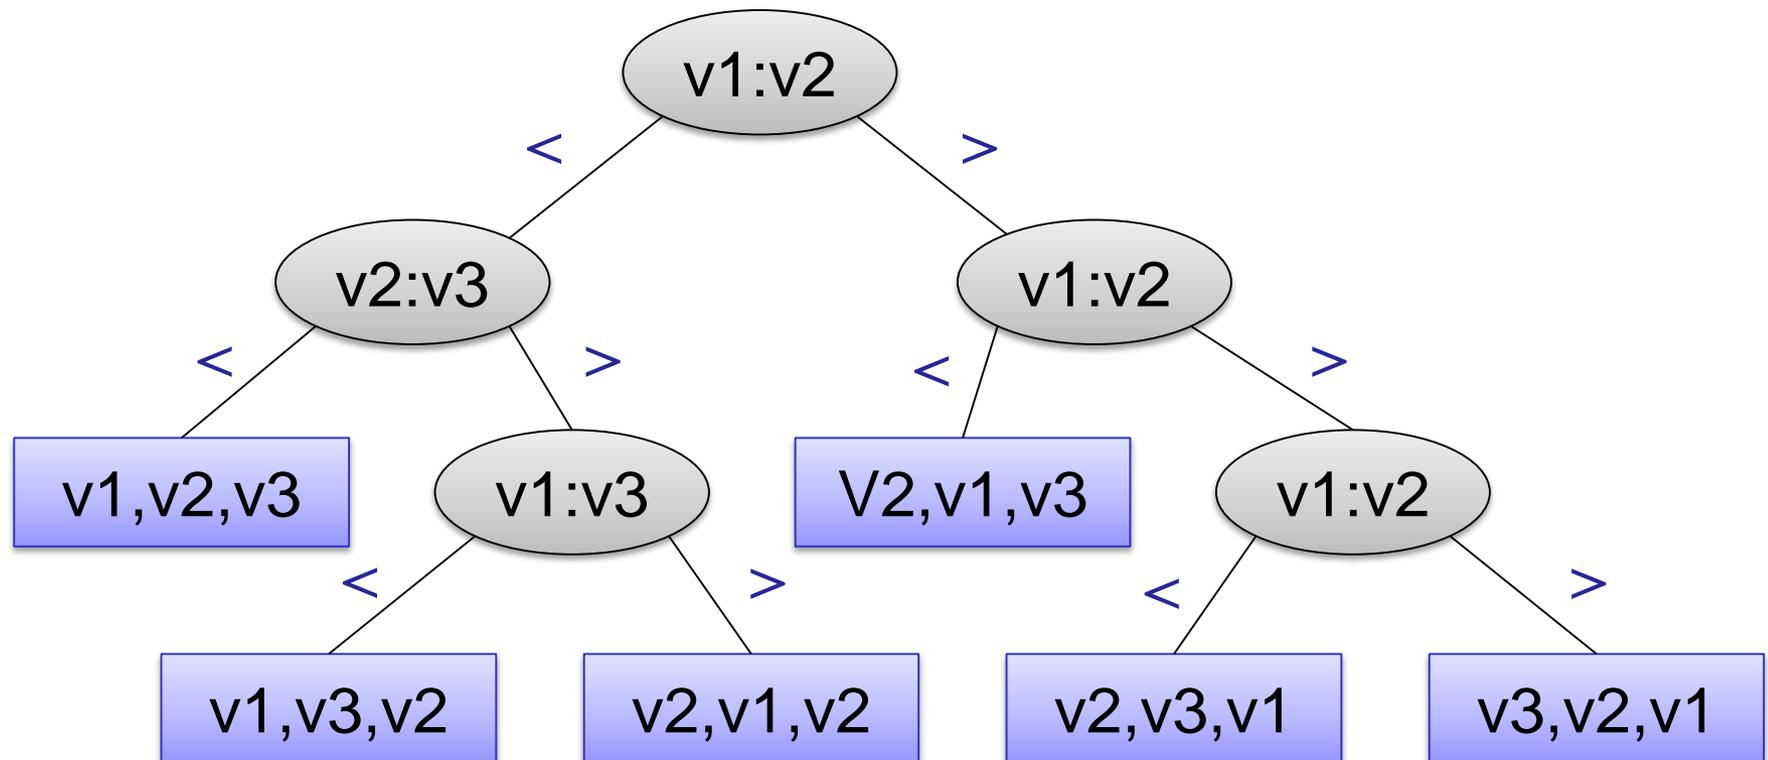
Alberi di decisione (1/3)

- Un albero di decisione rappresenta i confronti eseguiti da un algoritmo su un dato input
- Il seguente esempio indica l'albero di decisione sull'insieme $\{v1,v2,v3\}$



Alberi di decisione (2/3)

- Dato un insieme di n valori, sono possibili $n!$ permutazioni (possibili ordinamenti) \rightarrow l'albero di decisione deve quindi avere $n!$ foglie.
- L'esecuzione di un algoritmo A corrisponde ad un cammino sull'albero di decisione corrispondente all'input dato.



Alberi di decisione (2/4)

- Riassumendo:
 - Albero binario;
 - Deve contenere $n!$ foglie
 - Il cammino da una radice ad una foglia rappresenta l'esecuzione dell'algoritmo su un'istanza.
- Il più **lungo** cammino dalla radice ad una foglia rappresenta il numero di confronti che l'algoritmo deve eseguire nel **caso peggiore**.

Il lower bound $\Omega(n \log n)$

- **Teorema:** qualunque albero di decisione che ordina n elementi ha altezza $\Omega(n \log n)$
- **Corollario:** nessun algoritmo di ordinamento basato sui confronti ha complessità migliore di $\Omega(n \log n)$

Dimostrazione del teorema

- Un albero di decisione è binario;
- Un albero binario di altezza h non ha più di 2^{h-1} foglie
- Il nostro albero deve avere almeno $n!$ foglie, quindi:
 - $2^{h-1} \geq n! \rightarrow h-1 \geq \log(n!)$
 - $n! \geq (n/e)^n$ (approssimazione di Stirling)
 - $h-1 \geq \log(n!) \geq \log(n/e)^n = n \log(n) - n \log(e) = \Omega(n \log n)$

Quindi?

- Un importante corollario del teorema che fissa $\Omega(n \log n)$ come lower bound per il problema dell'ordinamento nel modello basato sui confronti è che gli algoritmi **heapSort** e **mergeSort** sono algoritmi **ottimi** (con complessità asintotica ottima).



Ordinamenti lineari

(per dati di input con proprietà particolari)

Ordinamento di n interi in [1,n]

Abbiamo n interi distinti con valore compreso nell'intervallo [1,n]

In quanto tempo possiamo ordinarli?

- $O(1) \rightarrow$ l'unico ordinamento possibile è $\{1,2,3,4,5,6,\dots,n\}$
- Contraddice il lower bound?
- No! Perché?

Ordinamento di n interi in [1,n]

Abbiamo n interi distinti con valore compreso nell'intervallo [1,n]

In quanto tempo possiamo ordinarli?

- $O(1) \rightarrow$ l'unico ordinamento possibile è $\{1,2,3,4,5,6,\dots,n\}$
- Contraddice il lower bound?
- No! Perché? \rightarrow **Siamo fuori dal modello basato sui confronti**



IntegerSort: fase 1

Nuovo problema, meno banale:

"ordinare n interi con valori in $[1, k]$ "

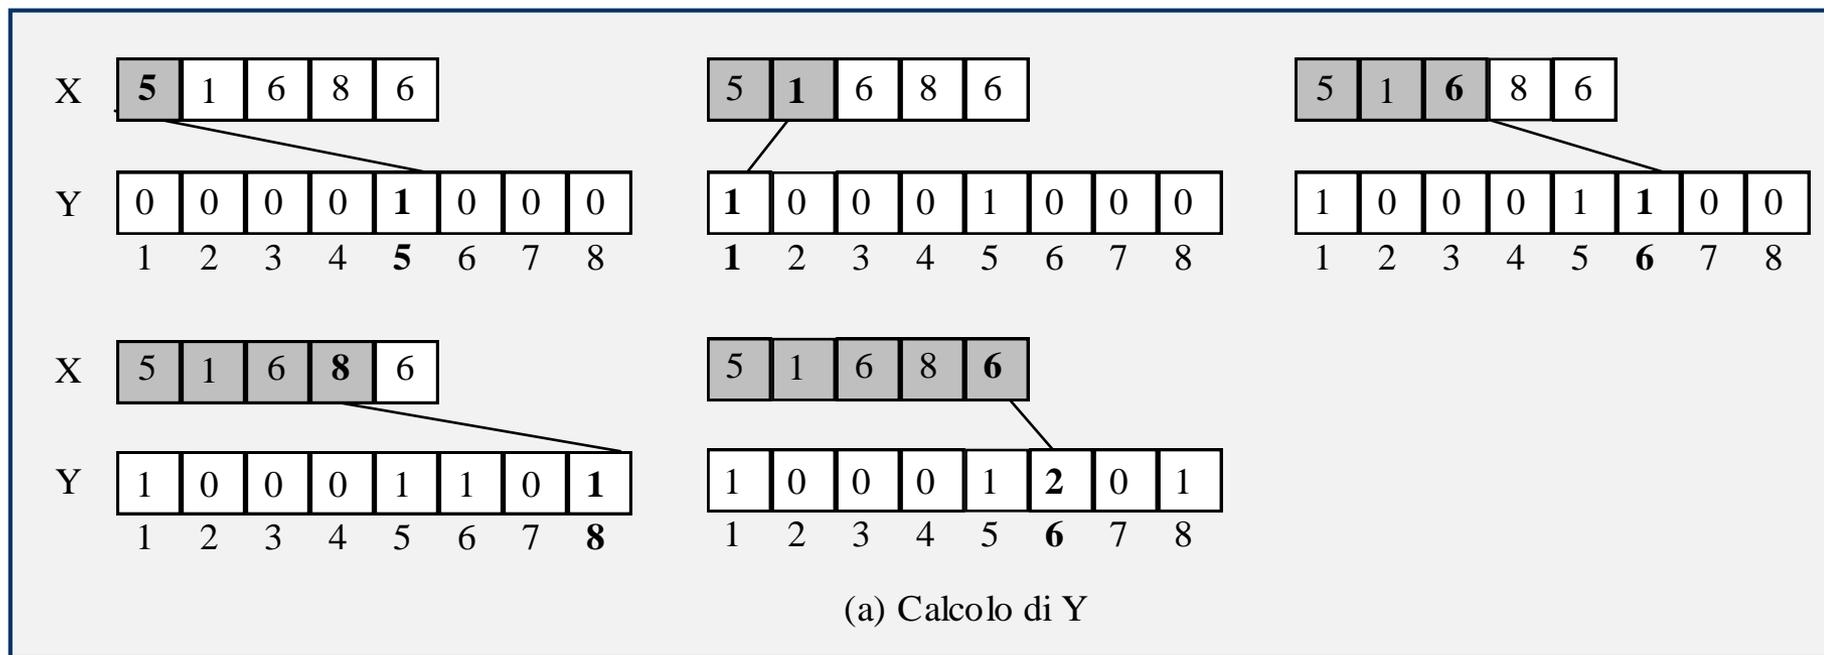
Strategia: mantiene un array Y di k contatori tale che

$Y[x]$ = numero di volte che il valore x compare nell'array di input X

IntegerSort: fase 1

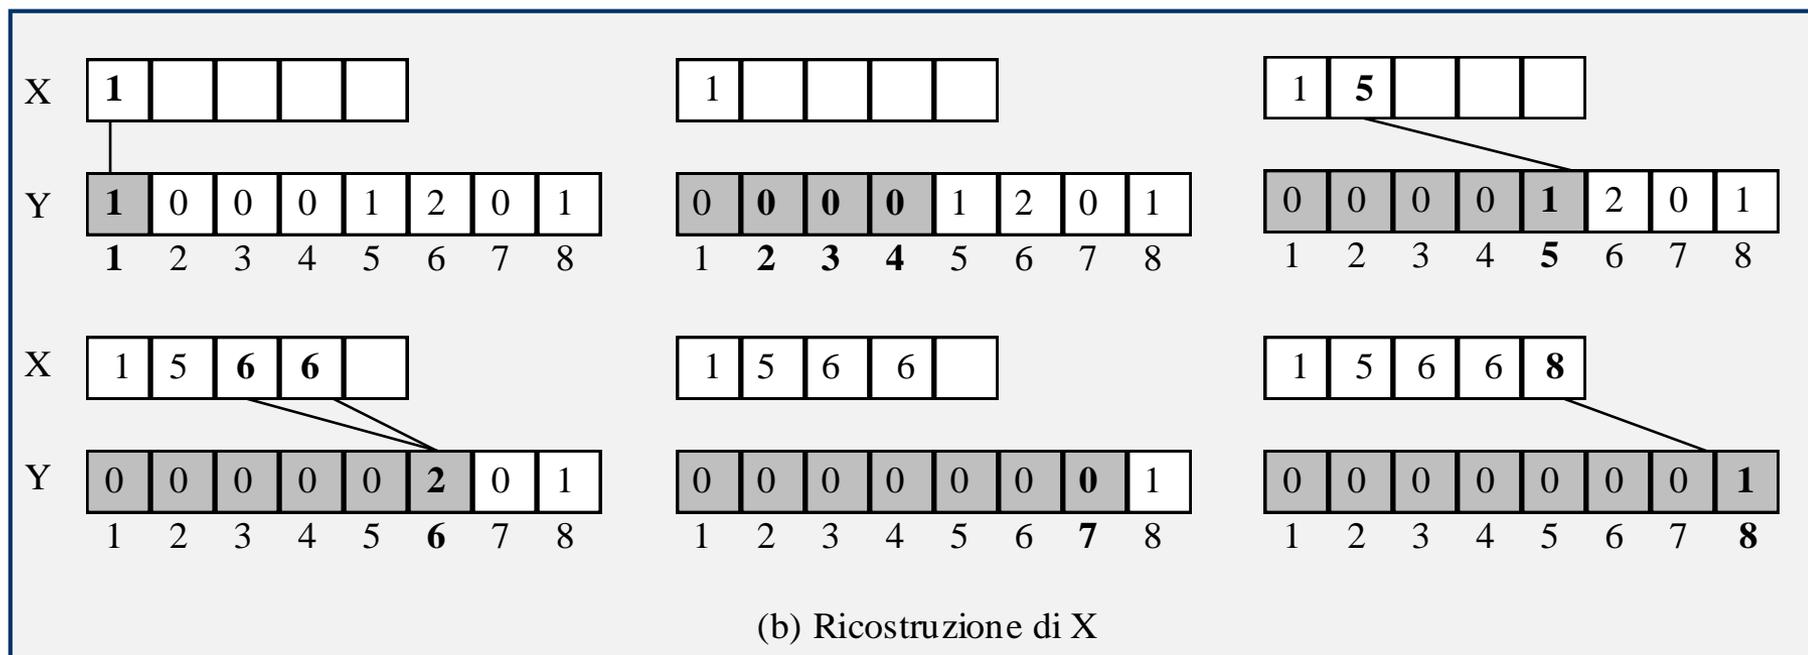
- ESEMPIO:

array X di **5** interi compresi tra 1 e 8



IntegerSort: fase 2

Dopo aver contato quanto volte si ripete ogni elemento in X , scorriamo Y da sinistra verso destra e, se $Y[x]=k$, scriviamo in X il valore x per k volte



IntegerSort: pseudocodice

```
Algoritmo integerSort(intero k, array X di dimensione n)
Sia Y un array di dimensione k;
//inizializzo tutte le celle di Y a 0;
for(int i ← 0; i < k; i++) { Y[i] ← 0; }
//scandisco X ed ogni volta che X contiene un valore p
//incremento di uno il valore in Y[p]
for(int h ← 0; h < n; h++) { Y[X[h]] ← Y[X[h]] + 1; }
j ← 1;
//scandisco Y, se Y[t]=k con k > 0, scrivo in X
//il valore t per k volte
for( t ← 0; t < k; t++ ) {
    while( Y[t] > 0 ){
        X[j] ← t; j++; Y[t] ← Y[t]-1;
    }
}
```

IntegerSort: analisi

L'algoritmo IntegerSort richiede:

- Tempo $O(k)$ per inizializzare Y (creo Y e inizializzo ogni sua cella a 0)
- Tempo $O(n)$ per scandire X (contare i suoi valori e incrementare i contatori in Y)
- Tempo $O(n+k)$ per ricostruire X (scandire Y e riscrivere gli n valori in X)

Quindi *integerSort* richiede un tempo pari a $O(n+k)$. Questo significa che, finché k è proporzionale con n ($k = O(n)$), il costo di **integerSort** è lineare con n ($O(n)$). Questa proprietà si perde se si possono avere valori di k molto grandi.

Es. per $k = n^5$ il costo di *integerSort* sarà $O(n + n^5) = O(n^5)$.

BucketSort

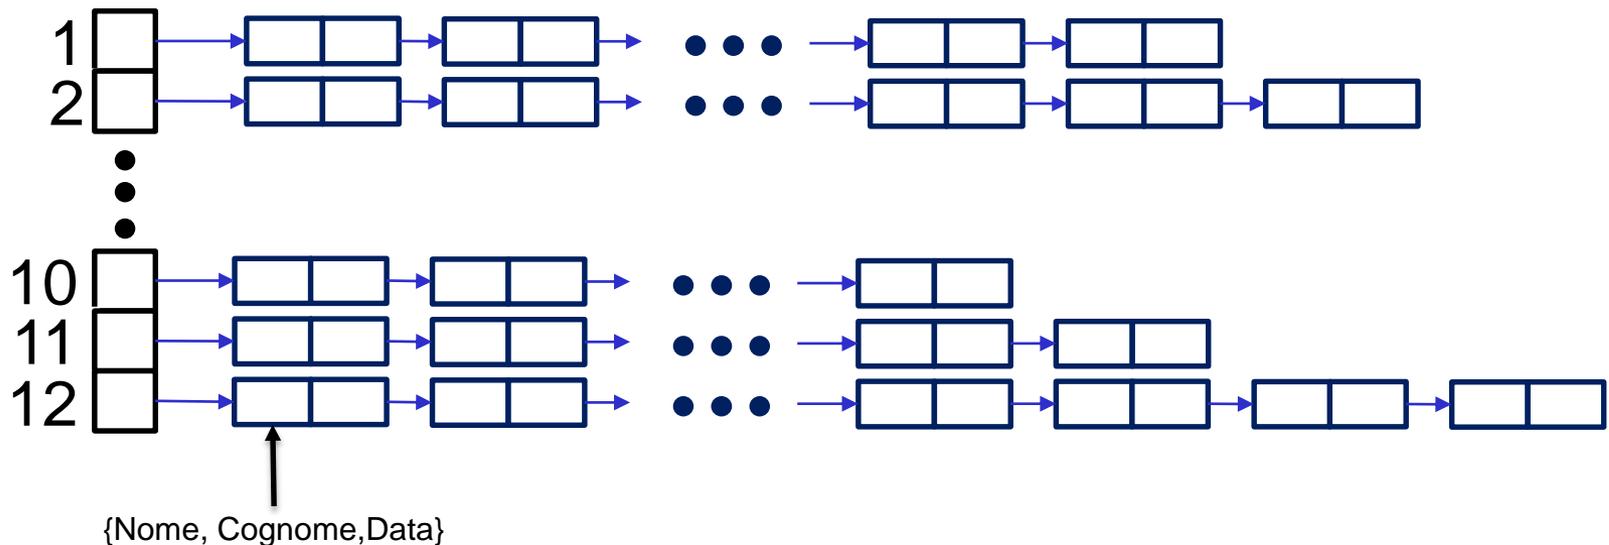
E se invece di interi vogliamo ordinare altri tipi di elementi (esempio le persone in una lista in base al loro mese di nascita)?

Per ordinare n record con chiavi intere in $[1, k]$

- Basta mantenere un **array di liste**, anziché di contatori, ed operare come per IntegerSort
- La lista $Y[x]$ conterrà gli elementi con chiave uguale a x
- Per ottenere una lista ordinata vado poi a concatenare le liste in Y
- Tempo $O(n+k)$ come per IntegerSort

BucketSort: esempio

- Ho una lista di 1000 record contenenti le seguenti informazioni sulle persone:
 - Nome; Cognome; Data di nascita (gg/mm/aaaa)
- Ordinare i record sulla base del mese di nascita delle persone
- Ci sono solo 12 mesi quindi userò un array di liste con 12 caselle





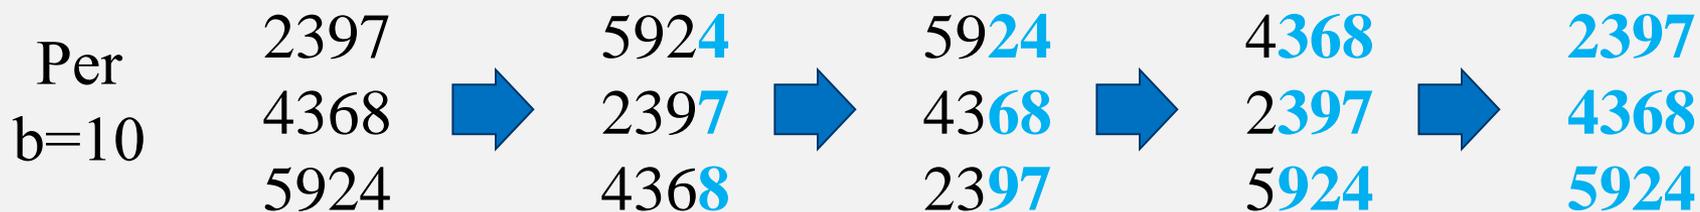
Stabilità

- Un algoritmo è stabile se preserva l'ordine iniziale tra elementi con la stessa chiave
- Il *BucketSort* può essere reso stabile appendendo gli elementi di X in coda alla opportuna lista $Y[i]$

RadixSort

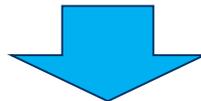
Come abbiamo visto l'*BucketSort* funziona bene quando k è dello stesso ordine di n . Che fare quando k è molto grande?

- Rappresentiamo gli elementi in base b (binario, decimale, esadecimale, ecc.), ed eseguiamo una serie di *BucketSort*
- Partiamo ordinando i numero usando come chiave la cifra meno significativa e poi ci spostiamo verso quella più significativa.



RadixSort: correttezza

- Se x e y hanno una diversa t -esima cifra, la t -esima passata di *BucketSort* li ordina
- Se x e y hanno la stessa t -esima cifra, la proprietà di stabilità del *BucketSort* li mantiene ordinati correttamente



Dopo la t -esima passata di *BucketSort*, i numeri sono correttamente ordinati rispetto alle t cifre meno significative

RadixSort: tempo di esecuzione

Se usiamo come base per il *bucketSort* un valore $\mathbf{b} = \Theta(\mathbf{n})$, l'algoritmo *radixSort* ordina \mathbf{n} numeri interi compresi tra $[\mathbf{1}, \mathbf{k}]$, in tempo:

$$T(n) = O\left(n \left(\frac{\log(k)}{\log(n)}\right)\right)$$