

# Programación II

**Bloque temático 1.** Lenguajes de programación

**Bloque temático 2.** Metodología de programación

**Bloque temático 3.** Esquemas algorítmicos

**Tema 4.** Introducción a los Algoritmos

**Tema 5.** Algoritmos voraces, heurísticos y aproximados

**Tema 6.** Divide y Vencerás

---

**Tema 7.** Ordenación

---

**Tema 8.** Programación dinámica

**Tema 9.** Vuelta atrás

**Tema 10.** Ramificación y poda

**Tema 11.** Introducción a los Algoritmos Genéticos

**Tema 12.** Elección del esquema algorítmico

Tema 7. Ordenación

## Tema 7. Ordenación

**7.1.** Introducción

**7.2.** Ordenación por burbuja (Bubble sort)

**7.3.** Ordenación por selección (Selection sort)

**7.4.** Ordenación por inserción (Insertion sort)

**7.5.** Comparación: algoritmos  $O(n^2)$

**7.6.** Ordenación rápida (Quicksort)

**7.7.** Ordenación por fusión (Mergesort)

**7.8.** Ordenación por montículo (Heapsort)

**7.9.** Comparación: algoritmos  $O(n \log n)$

**7.10.** Ordenación por cajas (Bin sort)

**7.11.** Ordenación por base (Radix sort)

**7.12.** Comparación: algoritmos  $O(n)$

**7.13.** Algoritmos de ordenación externos

**7.14.** Resumen

**7.15.** Bibliografía

Tema 7. Ordenación

7.1 Introducción

## 7.1 Introducción

Uno de los problemas fundamentales de la ciencia de la computación consiste en *ordenar una lista de elementos*

Existen infinidad de algoritmos de ordenación

- algunos son simples e intuitivos (e ineficientes)
- otros son más complejos (pero también más eficientes)

Según donde se realice la ordenación estos algoritmos se pueden dividir en:

- *Algoritmos de ordenación interna*: la ordenación se realiza en la memoria del ordenador
- *Algoritmos de ordenación externa*: la ordenación se realiza en memoria secundaria (disco duro)

También pueden clasificarse en base a su **estabilidad**:

- un algoritmo de ordenación es estable si mantiene el orden relativo que tenían originalmente los elementos con claves iguales

Cuando se dispone de varios algoritmos para un mismo propósito, como es el caso de los algoritmos de ordenación, la elección del más apropiado se realizará comparando:

- **Complejidad computacional** (en notación  $O(n)$ ,  $\Theta(n)$  o  $\Omega(n)$ )
  - los algoritmos de ordenación más simples son  $O(n^2)$
  - los algoritmos de ordenación más eficientes son  $O(n \log n)$
  - existen algoritmos de ordenación  $O(n)$  pero sólo pueden aplicarse a determinados tipos de problemas
- **Uso de memoria** (también se usa la notación  $O(n)$ )
- **Facilidad de implementación** (menos importante)

## 7.2 Ordenación por burbuja (*Bubble sort*)

Algoritmo de ordenación sencillo, antiguo (1956) e **ineficiente** [5]

Recorre la tabla comparando parejas de elementos consecutivos

- intercambia sus posiciones si no están en el orden correcto
- Ejemplo de ejecución: ordenación del array {9,21,4,40,10,35}

Primera pasada:

```
{9,21,4,40,10,35} --> {9,21,4,40,10,35} (no se realiza intercambio)
{9,21,4,40,10,35} --> {9,4,21,40,10,35} (intercambio entre el 21 y el 4)
{9,4,21,40,10,35} --> {9,4,21,40,10,35} (no se realiza intercambio)
{9,4,21,40,10,35} --> {9,4,21,10,40,35} (intercambio entre el 40 y el 10)
{9,4,21,10,40,35} --> {9,4,21,10,35,40} (intercambio entre el 40 y el 35)
```

Segunda pasada:

```
{9,4,21,10,35,40} --> {4,9,21,10,35,40} (intercambio entre el 9 y el 4)
{4,9,21,10,35,40} --> {4,9,21,10,35,40} (no se realiza intercambio)
{4,9,21,10,35,40} --> {4,9,10,21,35,40} (intercambio entre el 21 y el 10)
{4,9,10,21,35,40} --> {4,9,10,21,35,40} (no se realiza intercambio)
{4,9,10,21,35,40} --> {4,9,10,21,35,40} (no se realiza intercambio)
```

Aunque el array ya está ordenado se harían otras 3 pasadas más

## Implementación

```
public void bubble(int [] a) {
    int i, j, temp;
    // recorre el array n-1 veces
    for (i=1; i<a.length; i++) {
        // recorre todos los elementos
        for (j=0; j<a.length-1; j++) {
            // compara cada par de elementos consecutivos
            if (a[j] > a[j+1]) {
                // si están desordenados los intercambia
                temp = a[j];
                a[j]= a[j+1];
                a[j+1]= temp;
            }
        } // for j
    } // for i
}
```

## Prestaciones

Los dos bucles se realizan  $n-1$  veces

- su eficiencia es  $O(n^2)$
- el número de intercambios también es  $O(n^2)$

Una posible mejora consiste en añadir una bandera que indique si se ha producido algún intercambio durante el recorrido del array

- en caso de que no se haya producido ninguno el array se encuentra ordenado y se puede abandonar el método
- con esta mejora su tiempo de ejecución sigue siendo  $O(n^2)$

Es un algoritmo estable

Veremos otros métodos de ordenación simples de tiempo  $O(n^2)$

- ordenación por selección y por inserción
- *ambos métodos son mejores que este*

## 7.3 Ordenación por selección (*Selection sort*)

El algoritmo de ordenación por selección consiste en:

- *seleccionar* el mínimo elemento de la tabla e intercambiarlo con el primero
- *seleccionar* el mínimo en el resto de la tabla e intercambiarlo con el segundo
- y así sucesivamente...

- **Ejemplo de ejecución: ordenación del array {40,21,4,9,10,35}**

```
{40,21,4,9,10,35}
{4,21,40,9,10,35} <-- se selecciona el 4 y se cambia con el 40
{4,9,40,21,10,35} <-- se selecciona el 9 y se cambia con el 21
{4,9,10,21,40,35} <-- se selecciona el 10 y se cambia con el 40
{4,9,10,21,40,35} <-- se selecciona el 21 y se cambia con el 21
{4,9,10,21,35,40} <-- se selecciona el 35 y se cambia con el 40
```

## Implementación

```
void ordenaPorSelección (int[] a) {
    int min,i,j,aux;

    // para todos los elementos menos el último
    for (i=0; i<a.length-1; i++) {
        min=i;

        // busca el mínimo entre todos los elementos
        // después de la posición i
        for(j=i+1; j<a.length; j++)
            if (a[min] > a[j])
                min=j; // encontrado nuevo mínimo

        // intercambia elemento en la posición i con el
        // elemento seleccionado (el mínimo encontrado)
        aux=a[min];
        a[min]=a[i];
        a[i]=aux;
    } // for i
}
```

## Prestaciones

El bucle externo se realiza  $n-1$  veces

- en cada iteración el bucle interno se realiza  $n-i-1$  veces

$$\sum_{i=0}^{n-2} (n-i-1) = (n-1) \frac{(n-1)+1}{2} = \frac{n^2}{2} - \frac{n}{2}$$

- luego su eficiencia es  $O(n^2)$
- es mejor que el método de la burbuja en su constante oculta

El número de intercambios es  $O(n)$

- sólo se realiza un intercambio por cada iteración del bucle externo
- el número de intercambios cobra más importancia cuanto mayores son los elementos a intercambiar

Posible problema para algunas aplicaciones: es *inestable*

## 7.4 Ordenación por inserción (*Insertion sort*)

Este algoritmo divide la tabla en una parte ordenada y otra no

- la parte ordenada comienza estando formada por un único elemento (el que ocupa la primera posición de la tabla)
- los elementos son *insertados* uno a uno desde la parte no ordenada a la ordenada
- finalmente la parte ordenada acaba abarcando toda la tabla
- Ejemplo de ejecución: ordenación del array {40,21,4,9,10,35}

```
{40, 21, 4, 9, 10, 35}
{21, 40, 4, 9, 10, 35} <- el 21 ocupa su lugar en la parte ordenada
{4, 21, 40, 9, 10, 35} <- el 4 ocupa su lugar en la parte ordenada
{4, 9, 21, 40, 10, 35} <- el 9 ocupa su lugar en la parte ordenada
{4, 9, 10, 21, 40, 35} <- el 10 ocupa su lugar en la parte ordenada
{4, 9, 10, 21, 35, 40} <- el 35 ocupa su lugar en la parte ordenada
```

## Implementación

```
public void ordenaPorInserción(int[] a) {
    int ele, j;
    // introduce cada elemento en la parte ordenada
    for(int i=1; i<a.length; i++){
        ele = a[i]; // elemento a ordenar
        j = i-1; // comienzo de la parte ordenada
        // recorre la parte ordenada desplazando una
        // posición a la derecha los elementos mayores
        // que ele
        while(j>=0 && a[j]>ele) {
            a[j+1] = a[j];
            j = j - 1;
        }
        // pone ele en su posición en la parte ordenada
        a[j+1] = ele;
    }
}
```

## Prestaciones

El peor caso se da cuando la tabla se encuentra inicialmente ordenada en orden decreciente

- el bucle externo se realiza  $n-1$  veces
- en cada iteración el bucle interno se realiza  $i$  veces

$$\sum_{i=1}^{n-1} i = (n-1) \frac{1+(n-1)}{2} = \frac{n^2}{2} - \frac{n}{2}$$

- luego su eficiencia es  $O(n^2)$
- su constante oculta es mejor que la del método de la burbuja y que la del método de selección

Es mejor para tablas casi ordenadas

- cuando la tabla está ordenada su tiempo de ejecución es  $O(n)$

Es un algoritmo *estable*

## 7.5 Comparación: algoritmos $O(n^2)$

**Poca utilidad:** sólo para tablas pequeñas (pocas decenas de elementos)

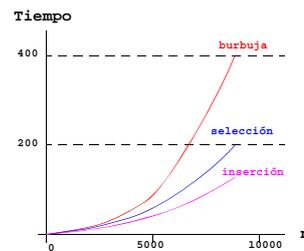
**Burbuja:** no usar nunca

**Selección:**

- ventaja: pocos intercambios ( $O(n)$ )
- desventaja: no es estable

**Inserción:**

- en general es mejor que selección
- en tablas casi ordenadas su tiempo de ejecución tiende a  $O(n)$
- es estable



## 7.6 Ordenación rápida (Quicksort)

Es un algoritmo DyV muy parecido al de la selección (búsqueda del  $k$ -ésimo menor elemento):

- se reorganiza la tabla en dos subtablas respecto a un pivote:
  - elementos mayores o iguales a un lado y menores al otro
  - después de la reorganización, el pivote ocupa exactamente el lugar que le corresponderá en la lista ordenada
- se repite el proceso de forma recursiva para cada subtabla
- Ejemplo de ejecución: ordenación del array  $\{21,40,4,9,10,35\}$

```
{21, 40, 4, 9, 10, 35} <- se elige el 21 como pivote
{ 9, 10, 4, 21, 40, 35} <- array reorganizado respecto al pivote
```

```
Subtabla { 9, 10, 4} <- se elige el 9 como pivote
{ 4, 9, 10} <- array reorganizado respecto al pivote
```

```
Subtabla {40, 35} <- se elige el 40 como pivote
{35, 40} <- array reorganizado respecto al pivote
```

## Implementación

La forma básica del algoritmo de ordenación rápida es:

```
método quicksort(entero[] t, entero ini, entero fin)
    si ini<fin entonces
        // reorganiza los elementos y retorna la pos.
        // del último elemento menor que el pivote
        p := reorganiza(t, ini, fin)
        // aplica quicksort a las dos subtablas
        quicksort(t,ini,p);
        quicksort(a,p+2,ult);
    fsi
fmétodo
```

- reorganiza: versión ligeramente diferente de la que vimos para el problema de la selección (también  $O(n)$ )
  - reorganiza los elementos a ambos lados del pivote, y además
  - deja el pivote en la posición que ocupará en el array ordenado

Como ocurre en la mayoría de los algoritmos DyV se pueden mejorar las prestaciones (aunque no su ritmo de crecimiento) aplicando un algoritmo directo para casos sencillos:

```
método quicksort(entero[] t, entero ini, entero fin)
    si fin-ini es suficientemente pequeño entonces
        // aplica el algoritmo directo
        ordenaPorInserción(t[ini..fin])
    sino
        // reorganiza los elementos y retorna la pos.
        // del último elemento menor que el pivote
        p := reorganiza(t, ini, fin)
        // aplica quicksort a las dos subtablas
        quicksort(t,ini,p);
        quicksort(t,p+2,ult);
    fsi
fmétodo
```

## Prestaciones

Es uno de los algoritmos de ordenación más utilizados ya que:

- Su *tiempo promedio es menor* que el de todos los algoritmos de ordenación de complejidad  $O(n \log n)$
- aunque tiene una posible desventaja: es *inestable*

Pero hay que tener en cuenta que su *peor caso es cuadrático*:

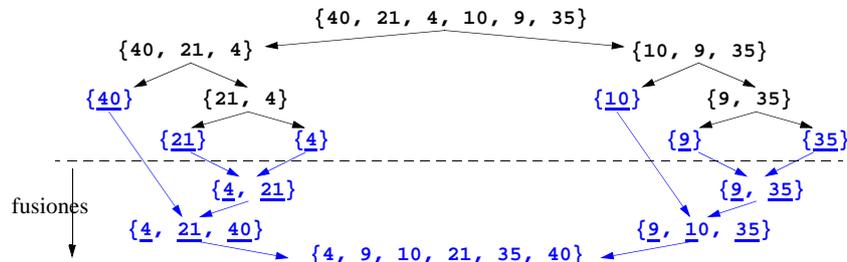
| Pivote  | Peor caso  | Caso promedio   |
|---|--|---|
| primer elemento                                       | $O(n^2)$<br>(p.e. si el array está ordenado)   | $O(n \log n)$   |
| intermedio de los elementos primero, central y último | $O(n^2)$<br>(pero en menos casos y más raros que si se usa sólo el primer elemento)    | $O(n \log n)$<br>(pero con un tiempo promedio algo menor) |
| pseudo-mediana  | $O(n \log n)$<br>pero con una constante multiplicativa muy grande ( <b>¡no usar!</b> ) |   |

- Utilizado por `java.util.Arrays.sort()` para arrays de tipos primitivos (para arrays de objetos usa el *mergesort*)

## 7.7 Ordenación por fusión (*Mergesort*)

Algoritmo basado en la técnica DyV

- divide el vector en dos partes iguales
- ordena por separado cada una de las partes (llamando recursivamente a ordenaPorFusión)
- mezcla ambas partes manteniendo la ordenación
- Ejemplo de ejecución: ordenación del array {40,21,4,10,9,35}



## Implementación

```
método ordenaPorFusión(entero[0..n-1] t)
    retorna entero[]
    si n es suficientemente pequeño entonces
        ordenaPorInserción(t) // algoritmo directo
        retorna t
    fsi
    t1 := ordenaPorFusión(t[0 .. n/2])
    t2 := ordenaPorFusión(t[n/2+1 .. n-1])
    retorna fusiona(t1, t2)
fmétodo
```

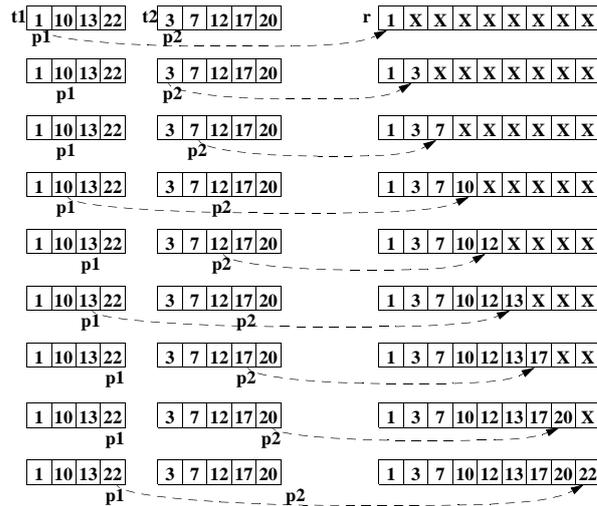
Si no se desea utilizar el algoritmo directo se puede sustituir el “si” por:

```
si n==1 entonces
    retorna t
fsi
```

Es fundamental disponer de una implementación eficiente ( $O(n)$ ) de fusiona:

```
método fusiona(entero[0..n1] t1, entero[0..n2] t2)
    retorna entero[0..n1+n2+1]
    p1:=0    p2:=0    n:=n1+n2+1
    entero[0..n] r
    mientras p1 <= n1 o p2 <= n2 hacer
        si p1<=n1 y (p2>n2 o t1[p1]<=t2[p2]) entonces
            r[p1 + p2] := t1[p1]
            p1 := p1 + 1
        fsi
        si p2<=n2 y (p1>n1 o t1[p1]>t2[p2]) entonces
            r[p1 + p2] := t2[p2]
            p2 := p2 + 1
        fsi
    fhacer
    retorna r
fmétodo
```

• **Ejemplo de ejecución de fusión:**



## Prestaciones

La eficiencia de fusión es  $O(n)$

El tiempo requerido por ordenaPorFusión es:

$$t(n) = 2 \cdot t(n/2) + O(n)$$

- estamos en el caso:  $s=b^k$  ( $2=2^1$ )
- luego  $t(n)$  es  $\Theta(n^k \log n) = \Theta(n \log n)$
- la eficiencia es la misma en los caso mejor, peor y promedio

Requiere, al menos, una *cantidad extra de memoria*  $O(n)$

- el pseudocódigo mostrado requiere  $O(n \log n)$

Se trata de un *algoritmo estable*

- *mergesort* es utilizado por `java.util.Collections.sort()` y por `java.util.Arrays.sort(Object[])`

## 7.8 Ordenación por montículo (*Heapsort*)

Existen dos versiones del algoritmo:

1. utilizando un montículo auxiliar
2. implementando el montículo sobre la propia tabla a ordenar

Utilizando un montículo auxiliar:

```
método ordenaPorMontículo(entero[0..n-1] t)
    Montículo m
    desde i:=0 hasta n-1 hacer
        insertarEnMontículo(m, t[i]) // O(log n)
    fhacer
    desde i:=0 hasta n-1 hacer
        t[i]:=extraeCimaDeMontículo(m) // O(log n)
    fhacer
fmétodo
```

Fácilmente implementable utilizando una *PriorityQueue*

## Implementación sobre la propia tabla

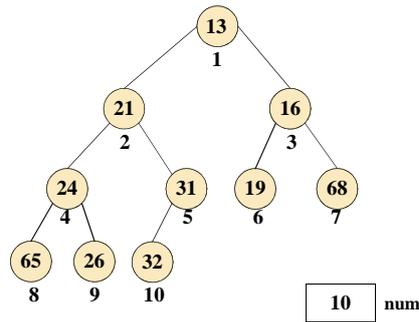
Utiliza la implementación sobre un array descrita en EDA

Un montículo binario es un árbol binario completo ordenado

- el padre siempre es menor que sus hijos

Para el elemento  $i$ :

- el hijo izquierdo está en  $2 \cdot i$
- el hijo derecho en  $2 \cdot i + 1$
- el padre está en  $i / 2$



La posición 0 no se utiliza para facilitar la implementación

|   |    |    |    |    |    |    |    |    |    |    |
|---|----|----|----|----|----|----|----|----|----|----|
|   | 13 | 21 | 16 | 24 | 31 | 19 | 68 | 65 | 26 | 32 |
| 0 | 1  | 2  | 3  | 4  | 5  | 6  | 7  | 8  | 9  | 10 |

## Prestaciones

Para la primera implementación ambos lazos se realiza  $n$  veces y en cada iteración realizan una operación  $O(\log n)$ :

- luego el algoritmo es  $O(n \log n) + O(n \log n) = O(n \log n)$
- la eficiencia del algoritmo es  $O(n \log n)$  en los casos peor, mejor y promedio

La implementación "in situ" también es  $O(n \log n)$

Requiere una cantidad de *memoria extra*  $O(n)$

- memoria necesaria para implementar un montículo de  $n$  nodos

Apropiado para mantener conjuntos de datos ordenados con continuas inserciones y extracciones

- *Heapsort* es utilizado para implementar la clase `PriorityQueue` de las *Java Collections* (usa la implementación sobre array)

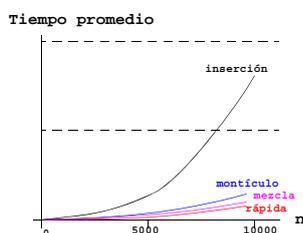
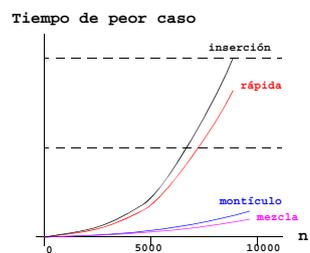
## 7.9 Comparación: algoritmos $O(n \log n)$

Tabla con los tiempos de ejecución de *peor caso* de los algoritmos  $O(n \log n)$

- comparados con inserción ( $O(n^2)$ )

La *ordenación por mezcla* es ligeramente más rápida que la basada en montículo

- pero tiene una desventaja: requiere más memoria auxiliar



En el *caso promedio* la *ordenación rápida* es la mejor

- pero tiene un peor caso  $O(n^2)$
- y NO es estable

## 7.10 Ordenación por cajas (*Bin sort*)

Utilizable cuando los datos a ordenar son valores discretos en un rango determinado

- p.e. números enteros en el rango  $1..m$

Se crean  $m$  colas (una para cada posible valor del campo llave)

- se coloca cada elemento en su cola (o caja) correspondiente
- se “vuelcan” las cajas en el array original

- Ejemplo: ordenación del array  $\{2,5,2,4,3,1,4,2,2,5,3\}$  ( $m=5$ )

```
caja 1 -> {1}
caja 2 -> {2,2,2,2}
caja 3 -> {3,3}
caja 4 -> {4,4}
caja 5 -> {5,5}
```

```
Array ordenado={1}+{2,2,2,2}+{3,3}+{4,4}+{5,5}=
                {1,2,2,2,2,3,3,4,4,5,5}
```

## Implementación

```
método ordenaPorCajas(entero[0..n-1] t, entero m)
    {valores de los elementos de t en el rango 1..m}
    Cola[m] c

    // inserta cada elemento en su caja
    desde j:=0 hasta n-1 hacer
        inserta(t[j],c[t[j]])
    fhacer

    // vuelca las cajas en el array
    i := 0
    desde k:=1 hasta m hacer
        // mete cada elemento en la posición que le
        // corresponde en el array ordenado
        mientras c[k] no está vacía hacer
            t[i] := extraePrimero(c[k])
            i:=i+1
        fhacer
    fhacer
fmétodo
```

## Prestaciones

**Análisis de eficiencia**

- el primer lazo (meter los elementos en cajas) se realiza  $n$  veces
- los lazos anidados para volcar las cajas en el array se realizan  $m+n-1$  veces en el peor caso (si todas están en la misma caja)
- luego su eficiencia es  $O(\max(m, n))$

**Requerimientos de memoria auxiliar:**

- una cola para cada posible valor:  $O(m)$
- un elemento de la cola para cada elemento del array:  $O(n)$

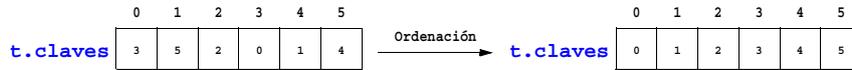
**Resultará eficiente cuando  $m < n$**

- en caso contrario puede resultar muy ineficiente
- p.e.: no es eficiente para ordenar un array de 8000 enteros de cualquier valor ( $m=2^{32} \approx 4 \cdot 10^9$ )

## Caso particular: ordenación por cubetas

Ordenación de un array de objetos cuyas claves de ordenación son los  $n$  primeros números enteros

- $m=n$  y no hay valores repetidos
- no es necesario hacer cajas



```

método ordenaPorCubetas (Objeto[0..n-1] t)
  desde i:=0 hasta n-1 hacer
    mientras t[i].clave≠i hacer
      intercambia t[i] con t[t[i]]
    fhacer
  fhacer
fmétodo

```

Eficiencia  $O(n)$  y no requiere memoria auxiliar

## 7.11 Ordenación por base (*Radix sort*)

Es una generalización del método de ordenación por cajas

- útil para ordenar valores discretos en un rango determinado (p.e. números enteros en el rango  $0..m-1$ )
- pero, a diferencia de la ordenación por cajas, *también puede ser eficiente cuando  $m \gg n$*

En general el método se puede aplicar siempre que los valores a ordenar sean secuencias de dígitos (o letras)

- se crea una cola para cada dígito
- se encola cada elemento en la cola correspondiente a su dígito menos significativo
- se vuelcan los contenidos de las colas en el array
- se vuelven a encolar, ahora en base a su segundo dígito menos significativo y así sucesivamente

## Ejemplo de ordenación por base

Ordenación del array: {0, 1, 81, 64, 23, 27, 4, 25, 36, 16, 9, 49}

- cada valor se representa con 2 dígitos en base 10

- Encolado en base a su dígito menos significativo:

| 0 | 1    | 2 | 3  | 4    | 5  | 6     | 7  | 8 | 9    |
|---|------|---|----|------|----|-------|----|---|------|
| 0 | 1,81 | - | 23 | 64,4 | 25 | 36,16 | 27 | - | 9,49 |

- Se “vacían” las colas sobre el array:  
{0, 1, 81, 23, 64, 4, 25, 36, 16, 27, 9, 49}

- Encolado en base a su segundo dígito menos significativo:

| 0       | 1  | 2        | 3  | 4  | 5 | 6  | 7 | 8  | 9 |
|---------|----|----------|----|----|---|----|---|----|---|
| 0,1,4,9 | 16 | 23,25,27 | 36 | 49 | - | 64 | - | 81 | - |

- Finalmente se “vacían” de nuevo las colas sobre el array:  
{0, 1, 4, 9, 16, 23, 25, 27, 36, 49, 64, 81}

## Implementación

```
método ordenaPorBase(entero[0..n-1] t)
{cada valor se representa con k dígitos en base b}

Cola[0..b-1] cola // una cola por cada valor
                  // distinto del dígito

// realiza una ordenación para cada dígito
desde i:=0 hasta k-1 hacer

    // inserta cada elemento en su cola
    desde j:=0 hasta n-1 hacer
        d:=(t[j]/bi) % b // dígito i-ésimo de t[j]
        insertaAlFinal(t[j],cola[d])
    fhacer
```

```
// vuelca las cajas en el array
j := 0
desde b:=0 hasta b-1 hacer
    // mete cada elemento en la posición que le
    // corresponde en el array ordenado
    mientras cola[d] no está vacía hacer
        t[j] := extraePrimero(cola[d])
        j:=j+1
    fhacer
    fhacer // bucle d

    fhacer // bucle i
fmétodo
```

## Prestaciones

### Análisis de eficiencia

- el lazo externo se realiza  $k$  veces
- el primer lazo (meter los elementos en cajas) se realiza  $n$  veces
- los lazos anidados para volcar las cajas en el array se realizan en el peor caso  $b+n-1$  veces ( $O(n)$  cuando  $b \ll n$ )
- luego su eficiencia es  $O(k \cdot n)$

### Requerimientos de memoria auxiliar:

- una cola para cada valor del dígito:  $O(b)$
- un elemento de la cola para cada elemento del array:  $O(n)$

### Aumentando la base ( $b$ ) se disminuye el número de dígitos ( $k$ )

- pero van aumentando los requerimientos de memoria
- cuando  $b$  es comparable a  $n$  es como ordenación por cajas

## 7.12 Comparación: algoritmos $O(n)$

Podemos considerar la utilización de estos algoritmos cuando:

- se trata de ordenar valores discretos acotados dentro de un rango
- p.e. números enteros en el rango  $[0..m-1]$

La ordenación por cajas resultará eficiente cuando  $m < n$

La ordenación por base puede resultar eficiente en comparación con los algoritmos  $O(n \log n)$  incluso cuando  $m \gg n$

La ordenación por cubetas es la ordenación ideal para un caso muy particular:

- ordenación de un array de objetos cuyas claves de ordenación son los  $n$  primeros números

## 7.13 Algoritmos de ordenación externos

Hasta ahora hemos asumido que todos los datos a ordenar cabían en la memoria principal del ordenador

- pero, ¿y si queremos ordenar por superficie todas las viviendas de Madrid, o por edad los clientes de una multinacional, o ...?
- toda esa información (Gigabytes o Terabytes) se encontrará almacenada en memoria secundaria (discos duros, DVDs, ...)
- lo más seguro es que no quepa completa en la memoria principal (RAM) del computador

La información en memoria secundaria se almacena en ficheros

- formados por registros (datos de la vivienda o ficha del cliente)

Los tiempos de acceso a la memoria secundaria son mucho mayores que a memoria principal (RAM)

- del orden de 1000 veces mayores

El sistema operativo realiza la lectura de los datos de un fichero por bloques de tamaño fijo (p.e. 1024bytes)

- en un bloque pueden caber varios registros consecutivos
- el bloque se almacena en un buffer de memoria

Si los datos que se desea leer ya se encuentran en el buffer, no se realiza otra lectura sobre el dispositivo

- luego el acceso secuencial a los registros minimiza el número de lecturas sobre memoria secundaria

Por consiguiente, los algoritmos de ordenación externa deberán:

- minimizar el número de accesos a memoria secundaria
- realizar el acceso a los registros de forma secuencial

La mayoría de los algoritmos de ordenación externos se basan en la ordenación por mezcla (*mergesort*)

## Ordenación por mezcla directa

Supongamos que toda la información a ordenar se encuentra almacenada en un fichero ( $f$ ) con  $n$  registros

- se comienza copiando esa información en dos ficheros ( $f_1$  y  $f_2$ ) de longitud  $n/2$
- además se utilizan otros dos ficheros auxiliares ( $g_1$  y  $g_2$ )

Proceso de ordenación:

- se lee el primer registro de  $f_1$  y el primero de  $f_2$ , se ordenan entre sí (fusión) y la pareja ordenada se guarda en  $g_1$
- los segundos registros se ordenan y se guardan en  $g_2$
- se continúa ordenando parejas y guardando las impares en  $g_1$  y las pares en  $g_2$
- se repite el proceso, ahora con parejas de elementos de  $g_1$  y  $g_2$  que forman cuartetos que se almacenan en  $f_1$  y  $f_2$
- el proceso continúa fusionando grupos de tamaño 8, 16, 32, ...

## Ejemplo de ordenación por mezcla directa

$f: \{28, 3, 93, 10, 54, 65, 30, 90, 10, 69, 8, 22, 31, 5, 96, 40, 85, 9, 39, 13, 8, 77, 10\}$

$f_1: \{28, 3, 93, 10, 54, 65, 30, 90, 10, 69, 8, 22\}$   
 $f_2: \{31, 5, 96, 40, 85, 9, 39, 13, 8, 77, 10\}$

$g_1: \{28, 31, 93, 96, 54, 85, 30, 39, 8, 10, 8, 10\}$   
 $g_2: \{3, 5, 10, 40, 9, 65, 13, 90, 69, 77, 22\}$

$f_1: \{3, 5, 28, 31, 9, 54, 65, 85, 8, 10, 69, 77\}$   
 $f_2: \{10, 40, 93, 96, 13, 30, 39, 90, 8, 10, 22\}$

$g_1: \{3, 5, 10, 28, 31, 40, 93, 96, 8, 8, 10, 10, 22, 69, 77\}$   
 $g_2: \{9, 13, 30, 39, 54, 65, 85, 90\}$

$f_1: \{3, 5, 9, 10, 13, 28, 30, 31, 39, 40, 54, 65, 85, 90, 93, 96\}$   
 $f_2: \{8, 8, 10, 10, 22, 69, 77\}$

$g_1: \{3, 5, 8, 8, 9, 10, 10, 10, 13, 22, 28, 30, 31, 39, 40, 54, 65, 69, 77, 85, 90, 93, 96\}$

## Mejora de la eficiencia

Sea  $m$  el máximo número de registros del fichero  $f$  que caben en memoria principal

Fase de preordenación:

- se toman los primeros  $m$  registros de  $f$ , se ordenan utilizando un algoritmo de ordenación interna y se guardan en  $f_1$
- igual para los siguientes  $m$  registros que se guardan en  $f_2$
- se continúa con el resto de grupos de  $m$  registros guardándoles en  $f_1$  y  $f_2$  alternativamente

A continuación se comienza el algoritmo de mezcla directa tal como se describió anteriormente, pero partiendo de grupos de  $m$  elementos

## Prestaciones

La eficiencia del método de mezcla directa es  $O(n \log n)$  (igual que *mergesort* interno)

El número de pasos que el algoritmo debe realizar es  $O(\log n)$

- en cada paso se leen y se escriben los  $n$  elementos
- luego es como si se hubiera leído y escrito  $\log n$  veces el fichero original

Utilizado directamente alguno de los algoritmos para ordenación interna:

- el número de lecturas y escrituras del fichero completo habría sido  $O(n)$

El algoritmo de mezcla directa constituye una *ganancia muy importante* ( $\log n \ll n$  para  $n$  grande)

## 7.14 Resumen

Utilizar algoritmos  $O(n^2)$  (*inserción y selección*) para:

- ordenar tablas pequeñas (decenas de elementos)
- el caso directo de los algoritmos de ordenación DyV

Utilizar algoritmos  $O(n \log n)$  (*rápida, mezcla y montículo*) para:

- tablas medianas o grandes cuando no se conoce el rango de los valores a ordenar (o el rango es muy grande)
- utilizar ordenación rápida cuando interesa un buen tiempo promedio (y se pueden asumir casos peores muy malos)

Utilizar algoritmos  $O(n)$  (*cajas, cubetas y base*) cuando:

- los valores a ordenar se distribuyen en un rango pequeño

En ocasiones también habrá que considerar factores como:

- estabilidad, memoria auxiliar y ordenación externa

## 7.15 Bibliografía

- [1] Brassard G., Bratley P., *Fundamentos de algoritmia*. Prentice Hall, 1997.
- [2] Aho A.V., Hopcroft J.E., Ullman J.D., *Estructuras de datos y algoritmos*. Addison-Wesley, 1988.
- [3] Sartaj Sahni, *Data Structures, Algorithms, and Applications in Java*. Mc Graw Hill, 2000
- [4] Entrada "*algoritmo de ordenamiento*" en la Wikipedia. [http://es.wikipedia.org/wiki/Algoritmo\\_de\\_ordenamiento](http://es.wikipedia.org/wiki/Algoritmo_de_ordenamiento)
- [5] Owen Astrachan. *Bubble Sort: An Archaeological Algorithmic Analysis*. <http://www.cs.duke.edu/~ola/papers/bubble.pdf>