

ANALIZA ALGORITMILOR

Acest capitol vă va familiariza cu concepția de bază folosite în această carte, referitor la proiectarea și analiza algoritmilor.

Începem cu o discuție asupra problemelor generale ale calculabilității și ale algoritmilor necesari pentru rezolvarea acestora, cu problema sortării, ca exemplu introductiv. Pentru a arăta cum vom specifica algoritmi prezentați, vom introduce un “pseudocod”, care ar trebui să fie familiar cititorilor obișnuiți cu programarea. Sortarea prin inserție, un algoritm simplu de sortare, va servi ca exemplu inițial. Vom analiza timpul de execuție pentru sortarea prin inserție, introducând o notație care să descrie modul în care crește acest timp odată cu numărul obiectelor aflate în operația de sortare. De asemenea vom introduce în proiectarea algoritmilor metoda *divide și stăpânește*, pe care o vom utiliza pentru dezvoltarea unui algoritm numit *sortare prin interclasare*. Vom încheia cu o comparație între cei doi algoritmi de sortare.

1. Algoritmi

Fără a fi foarte exacti, spunem că un *algoritm* este o procedură de calcul bine definită care primește o valoare sau o mulțime de valori ca *date de intrare* și produce o anumită valoare sau o mulțime de valori ca *date de ieșire*. Astfel, un algoritm este un șir de pași care transformă datele de intrare în date de ieșire.

Putem de asemenea să privim un algoritm ca pe un instrument de rezolvare a *problemelor de calcul bine* definite. Enunțul problemei specifică, în termeni generali, relația dorită intrare/ieșire. Algoritmul descrie o anumită procedură de calcul pentru a se ajunge la această legătură intrare/ieșire.

Vom începe studiul algoritmilor cu problema sortării unui șir de numere în ordine nedescrescătoare. Această problemă apare frecvent în practică și furnizează o bază foarte utilă pentru introducerea multor metode standard pentru proiectarea și analiza algoritmilor. Iată cum vom defini formal *problema sortării*:

Date de intrare: Un șir de n numere $\langle a_1, a_2, \dots, a_n \rangle$.

Date de ieșire: O permutare (reordonare) a șirului inițial, $\langle a'_1, a'_2, \dots, a'_n \rangle$ astfel încât $a'_1 \leq a'_2 \leq \dots \leq a'_n$.

Fiind dat un șir de intrare ca, de exemplu $\langle 26, 31, 41, 41, 58, 59 \rangle$. Un șir de intrare ca cel de mai sus se numește *o instanță* a problemei de sortare. În general o *instanță a unei probleme* se va înțelege mulțimea tuturor datelor de intrare (care satisfac restricțiile impuse în definirea problemei) necesare pentru a determina o soluție a problemei.

Sortarea este o soluție fundamentală în informatică (multe programe o folosesc ca pas intermediar) și, ca urmare, a fost dezvoltat un număr mare de algoritmi de sortare. Care algoritm este cel mai bun pentru o aplicație dată depinde de obiecte care trebuie sortate, de gradul în care aceste obiecte sunt deja sortate într-un anumit fel și de tipul de mediu electronic care urmează să fie folosit: memorie principală, discuri sau benzi magnetice.

Un algoritm este *corect* dacă, pentru orice instanță a sa, se termină furnizând ieșirea corectă. Vom spune că un algoritm corect *rezolvă* problema de calcul dată. Un algoritm incorect s-ar putea să nu se termine deloc în cazul unor anumite instanțe de intrare, sau s-ar putea termina producând un alt răspuns decât cel dorit. Contrar a ceea ce s-ar putea crede, algoritmi incorecți pot fi uneori utili dacă rata lor de eroare poate fi controlată.

Concret un algoritm poate fi specificat printr-un program pentru calculator sau chiar un echipament hardware. Singura condiție este aceea ca specificațiile să producă o descriere precisă a procedurii de calcul care urmează a fi parcursă.

La acest curs vom descrie algoritmi sub forma unor programe scrise într-un *pseudocod* care seamănă foarte mult cu limbajele C, Pascal sau Algol. Dacă sunteți cât de cât familiarizați cu oricare din acestea, nu veți avea probleme în a citi algoritmi noștri. Ceea ce diferențiază codul real de pseudocod este faptul că vom folosi metoda cea mai clară și mai concisă pentru a descrie un algoritm dat. O altă diferență dintre pseudocod și codul real este aceea că pseudocodul nu se ocupă de detalii de utilizare. Problemele abstractizării datelor sau a tratării erorilor sunt deseori ignorate, pentru a transmite cât mai concis esența algoritmului.

1.1 Sortarea prin inserție

Începem cu sortarea prin inserție, care este un algoritm eficient pentru sortarea unui număr mic de obiecte. Sortarea prin inserție funcționează în același fel în care mulți oameni sortează un pachet de cărți de joc obișnuite. Se începe cu pachetul așezat pe masă cu fața în jos și cu mâna stângă goală. Apoi luăm câte o

carte de pe masă îi o inserăm în poziția corectă în mâna stângă. Pentru a găsi poziția corectă pentru o carte dată, o comparăm cu fiecare dintre cărțile aflate deja în mâna stângă, de la dreapta la stânga.

Pseudocodul pentru sortarea prin inserție este prezentat ca o procedură numită **Sortează Prin - Inserție**, care are ca parametru un vector $A[1..n]$ conținând un șir de lungime n , care urmează a fi sortat. (Pe parcursul codului, numărul de elemente ale lui A va fi notat cu $lungime[A]$.) Numerele de intrare sunt sortate pe loc, în cadrul aceluiași vector A ; cel mult un număr constant dintre acestea sunt memorate în zone de memorie suplimentară. Când **Sortează Prin - Inserție** se termină, vectorul inițial A va conține elementele șirului de ieșire sortat.

Sortează Prin - Inserție(A)

```

1: pentru  $j \leftarrow 2$ ,  $lungime[A]$  execută
2:  $cheie \leftarrow A[j]$ 
3: ▷ Inserează  $A[j]$  în șirul sortat  $A[1..j-1]$ 
4:  $i \leftarrow j - 1$ 
5: cât timp  $i > 0$  și  $cheie < A[i]$  execută
6:  $A[i+1] \leftarrow A[i]$ 
7:  $i \leftarrow i - 1$ 
8:  $A[i+1] \leftarrow cheie$ 

```

```

5 2 4 6 1 3
2 5 4 6 1 3
2 4 5 6 1 3
2 4 5 6 1 3
1 2 4 5 6 3
1 2 3 4 5 6 stop

```

Figura 1.2. Modul de operare a procedurii **Sortează Prin - Inserție**, asupra vectorului $A = \langle 5, 2, 4, 6, 1, 3 \rangle$. Poziția indicelui j este indicată printr-un cerc.

Figura 1.2 ilustrează modul de funcționare a acestui algoritm pentru $A = \langle 5, 2, 4, 6, 1, 3 \rangle$. Indicele j corespunde cărții care urmează a fi inserată în mâna stângă. Elementele $A[1..j-1]$ corespund mulțimii de cărți din mână, deja sortate, iar elementele $A[i+1..n]$ corespund pachetului de cărți aflate pe masă. Indicele se deplasează de la stânga spre dreapta în interiorul vectorului. La fiecare iterație, elementul $A[j]$ este ales din vector (linia 2). Apoi, plecând de la poziția $j-1$, elementele sunt, succesiv deplasate o poziție spre dreapta până când este găsită poziția corectă pentru $A[j]$ (liniile 4-7), moment în care acesta este înserat (linia 8).

Convenții pentru pseudopod

La scrierea pseudocodului vom folosi următoarele convenții:

1. Indentarea (spațiu liber) indică o structură de bloc. De exemplu, corpul ciclului **pentru (for)**, care începe în linia 1, constă din liniile 2-8, iar corpul ciclului **cât timp**, care începe în linia 5, constă din liniile 6-7, dar nu și linia 8. Stilul nostru de indentare se aplică și structurilor de tipul **dacă – atunci - altfel**. Folosirea indentării în locul unor indicatori de bloc de tipul **begin** și **end**, reduce cu mult riscul de confuzie, îmbunătățind claritatea prezentării.
2. Ciclurile de tipul **cât timp**, **pentru**, **repetă** și construcțiile condiționale **dacă**, **atunci** și **altfel** au aceeași interpretare ca și structurile similare din Pascal.
3. Simbolul ▷ indică faptul că restul liniei este un comentariu.
4. O atribuire multiplă de forma $i \leftarrow j \leftarrow e$ înseamnă atribuirea valorii expresiei e ambelor variabile i și j ; aceasta ar trebui tratată ca un echivalent al atribuirii $i \leftarrow e$, urmată de atribuirea $i \leftarrow j$.

5. Variabilele (de exemplu i, j , *cheie*) sunt locale pentru o procedură dată. Nu vom utiliza variabile globale fără a preciza acest tip de lucru în mod explicit.
6. Elementele unui vector sunt accesate specificând numele vectorului urmat de indice în paranteze drepte. De exemplu $A[i]$ indică elementul de rang i al vectorului A . Notăția “..” este folosită pentru a indica un domeniu de valori în cadrul unui vector. Astfel $A[1..j]$ indică un subvector al lui A constând din elementele $A[1], A[2] \dots A[j]$.
7. Datele compuse sunt, în mod uzual, organizate în *obiecte* care conțin *attribute* sau *câmpuri*. Un anumit câmp este accesat folosind numele câmpului urmat de numele obiectului său în paranteze drepte. De exemplu, tratăm un vector ca pe un obiect cu atributul *lungime* indicând numărul de elemente ale acestuia. Pentru a specifica numărul de elemente ale unui vector A , se va scrie $lungime[A]$. Deși vom folosi paranteze drepte atât pentru indexarea elementelor unui vector, cât și pentru attributele obiectelor, va fi clar din context care este interpretarea corectă. O variabilă reprezentând un vector sau un obiect este tratată ca un pointer spre datele care reprezintă vectorul sau obiectul. Pentru toate câmpurile f ale unui obiect x atribuirea $y \leftarrow x$, are ca efect $f[y]=f[x]$. Mai mult dacă acum avem $f[x] \leftarrow 3$, atunci nu numai $f[y]=3$, dar și $f[x]=3$. Cu alte cuvinte, x și y indică spre același obiect după atribuirea $y \leftarrow x$. Uneori un pointer nu se va referi nici la un obiect. În acest caz special pointerul va primi valoarea NIL.
8. Parametrii sunt transmiși unei proceduri *prin valoare*: procedura apelată primește propria sa copie a parametrilor și dacă atribuie o valoare unui parametru, schimbarea nu este văzută de procedura apelantă. Când obiectele sunt transmise procedurii, este copiat doar pointerul spre datele reprezentând obiectul, nu și câmpurile acestuia. De exemplu dacă x este un parametru al unei proceduri apelate, atribuirea $y \leftarrow x$ în cadrul procedurii apelate nu este vizibilă din procedura apelantă. Atribuirea $f[x] \leftarrow 3$ este, totuși, vizibilă.

2. Analiza algoritmilor

Analiza unui algoritm a ajuns să însemne prevederea resurselor pe care algoritmul le solicită. Uneori, resurse ca memoria, lățimea benzii de comunicație, porți logice sunt prima preocupare, dar de cele mai multe ori, vrem să măsurăm timpul de execuție necesar algoritmului. În general, analizând mai mulți algoritmi pentru o anumită problemă, cel mai eficient poate fi identificat ușor. O astfel de analiză poate indica mai mulți candidați viabili, dar câțiva algoritmi inferiori sunt, de obicei, eliminați în timpul analizei.

Înainte de a analiza un algoritm, trebuie să avem un model al tehnologiilor de implementare care urmează să fie folosită, incluzând un model pentru resursele acesteia și costurile corespunzătoare. În cea mai mare parte a acestei cărți vom presupune că tehnologia de implementare este un model de calcul generic cu un procesor, *mașină cu acces aleator (RAM)* și vom presupune că algoritmi vor fi implementați ca programe pentru calculator. În modelul RAM, instrucțiunile sunt executate una după alta, fără operații concurente.

Analiza, chiar și a unui singur algoritm, poate fi, uneori, o încercare dificilă. Matematica necesară poate să includă combinatorică, teoria probabilităților, dexteritate algebrică și abilitatea de a identifica cei mai importanți termeni într-o expresie. Deoarece comportarea unui algoritm poate fi diferită în funcție de datele de intrare, avem nevoie de un mijloc de exprimare a acestei comportări în formule simple, ușor înțelese. Deși pentru a analiza un algoritm, selectăm nu numai un anumit tip de model de mașină de calcul, rămân mai multe posibilități de alegere a felului în care decidem să exprimăm această analiză. Un scop imediat este de a găsi un mijloc de exprimare care să fie simplu de scris și de manevrat, care să arate principalele resurse necesare unui algoritm și să suprimă detaliile inutile.

2.1. Analiza sortării prin inserție.

Timpul de execuție necesar procedurii **Sortează – Prin - Inserție** depinde de intrare: sortarea a o mie de numere ia mai mult timp ca sortarea a trei numere. Mai mult decât atât, **Sortează – Prin - Inserție** poate să consume timpi diferiți pentru a sorta două șiruri de numere de aceeași dimensiune, în funcție de măsura în care acestea conțin numere aproape sortate. În general, timpul necesar unui algoritm crește odată cu dimensiunea datelor de intrare, astfel încât este tradițional să se descrie timpul de execuție al unui program în

funcție de dimensiunile datelor de intrare. În acest scop, trebuie să definim cu mai multă precizie termenii de “timp de execuție” și “dimensiunea datelor de intrare”

Definiția *dimensiunea datelor de intrare* depinde de problema studiată. Pentru multe probleme, cum ar fi sortarea sau calculul unei transformate Fourier discrete, cea mai naturală măsură este *numărul de obiecte din datele de intrare*-de exemplu, pentru sortare, un vector de dimensiune n . Pentru multe alte probleme, ca înmulțirea a doi întregi, cea mai bună măsură pentru dimensiunea datelor de intrare este *numărul total de biți* necesari pentru reprezentarea datelor de intrare în notație binară. Uneori este mai potrivit să exprimăm dimensiunea datelor de intrare prin două numere în loc de unul. De exemplu, dacă datele de intrare ale unui algoritm sunt reprezentate de un graf, datelor de intrare poate fi descrisă prin numărul de vârfuri și muchii ale grafului. Pentru fiecare problemă pe care o vom studia, vom indica măsura utilizată pentru dimensiunea datelor de intrare.

Timp de execuție a unui algoritm pentru un set de date de intrare este determinat de operații primitive sau “pași” executați. Este util să definim noțiunea de “pași”, astfel încât să fie cât mai independent de calculator. Pentru moment, să adoptăm următorul punct de vedere. Pentru execuția unei linii din pseudocod este necesară o durată constantă de timp. O anumită linie poate avea nevoie de un timp de execuție decât o alta, dar vom presupune că fiecare execuție a liniei i consumă timpul c_i , unde c_i este o constantă. Acest punct de vedere este conform cu modelul RAM și în același timp, reflectă, destul de bine, modul în care pseudocodul poate fi utilizat în cele mai multe cazuri concrete.

În prezentarea care urmează, expresia noastră pentru timpul de execuție al algoritmului **Sortează – Prin - Inserție** va evolua de la o formulă relativ complicată, care folosește toate costurile de timp c_i , la una

Mult mai simplă din notații, care este mai concisă și mai ușor de manevrat. Această notație mai simplă va face, de asemenea, ușor determinat dacă un algoritm este mai eficient decât altul.

Începem prin a relua prezentarea procedurii **Sortează – Prin - Inserție**, adăugând costul de timp pentru fiecare instrucțiune și un număr care reprezintă de câte ori aceasta este efectiv executată. Pentru fiecare $j=2,3,\dots,n; n = \text{lungime}[A]$, vom nota cu t_j numărul de execuții ale testului cât timp din linia 5 pentru valoarea fixată j . Vom presupune că un comentariu nu este o instrucțiune executabilă, prin urmare nu cere timp de calcul. Timpul de execuție al algoritmului este suma tuturor timpilor de execuție corespunzători

Sortează – Prin - Inserție(A)	<i>cost</i>	<i>timp</i>
1: pentru $j \leftarrow 2, \text{lungime}[A]$ execută	c_1	n
2: $\text{cheie} \leftarrow A[j]$	c_2	$n-1$
3: \triangleright Inserează $A[j]$ în șirul sortat $A[1..j-1]$	0	$n-1$
4: $i \leftarrow j -$	c_4	$n-1$
5: cât timp $i > 0$ și $\text{cheie} < A[i]$ execută	c_5	$\sum_{j=2}^n t_j$
6: $A[i+1] \leftarrow A[i]$	c_6	$\sum_{j=2}^n (t_j - 1)$
7: $i \leftarrow i - 1$	c_7	$\sum_{j=2}^n (t_j - 1)$
8: $A[i+1] \leftarrow \text{cheie}$	c_8	$n-1$

fiecărei instrucțiuni executate: o instrucțiune care consumă timpul c_i pentru execuție și este executată de n ori, va contribui cu $c_i n$ la timpul total de execuție. Pentru a calcula $T(n)$ timpul de execuție pentru **Sortează – Prin - Inserție**, vom aduna produsele mărimilor indicate în coloanele *cost* și *timp*, obținând:

$$T(n) = c_1 n + c_2 (n-1) + c_4 (n-1) + c_5 \sum_{j=2}^n t_j + c_6 \sum_{j=2}^n (t_j - 1) + c_7 \sum_{j=2}^n (t_j - 1) + c_8 (n-1).$$

Chiar pentru datele de intrare de aceeași marime, timpul de execuție al unui algoritm dat poate să depindă de conținutul datelor de intrare. De exemplu, pentru **Sortează – Prin - Inserție**, cazul cel mai favorabil apare când vectorul de intrare este deja sortat. Pentru fiecare $j = 2, 3, \dots, n$, vom găsi că $A[i] \leq \text{cheie}$ în linia 5, când i are valoarea inițială $j-1$. Rezultă $t_j = 1$ pentru $j = 2, 3, \dots, n$ și timpul de execuție în cazul cel mai defavorabil este:

$$T(n) = c_1 n + c_2(n-1) + c_4(n-1) + c_5(n-1) + c_8(n-1) = \\ = (c_1 + c_2 + c_4 + c_8)n - (c_5 + c_2 + c_4 + c_8).$$

Acest timp de execuție poate fi exprimat sub forma $an + b$ pentru anumite constante a și b care depind de timpii de execuție c_i fiind astfel o *funcție lineară* de n .

Dacă vectorul este sortat în ordine inversă – adică în ordine descrescătoare-obținem cazul cel mai defavorabil. În această situație trebuie să comparăm fiecare element $A[j]$ cu fiecare element din subvectorul $A[1..j-1]$, și astfel $t_j = j$ pentru $j = 2, 3, .. n$. Observând că

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

și

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

găsim că în cazul cel mai defavorabil timpul de execuție pentru **Sortează – Prin - Inserție** este

$$T(n) = c_1 n + c_2(n-1) + c_4(n-1) + c_5 \left(\frac{n(n+1)}{2} - 1 \right) + c_6 \left(\frac{n(n-1)}{2} \right) + c_7 \left(\frac{n(n-1)}{2} \right) + c_8(n-1) \\ = \left(\frac{c_5}{2} + \frac{c_6}{2} + \frac{c_7}{2} \right) n^2 + \left(c_1 + c_2 + c_4 + \frac{c_5}{2} + \frac{c_6}{2} + \frac{c_7}{2} + c_8 \right) n - (c_5 + c_2 + c_4 + c_8).$$

Rezultă că timpul de execuție în cazul cel mai defavorabil poate fi exprimat sub forma $an^2 + bn + c$, unde a, b, c depind, din nou de costurile c_i ale instrucțiunilor, fiind astfel o *funcție pătratică* de n .

De obicei, la fel ca la sortarea prin inserție, timpul de execuție al unui algoritm dat este fix pentru anumite date de intrare. Totuși, în ultimele capitole, vom întâlni câțiva algoritmi “aleatori” a căror comportare poate varia chiar pentru aceleași date de intrare.

2.2. Analiza celui mai defavorabil caz și a cazului mediu

În analiza sortării prin inserție am cercetat ambele situații extreme: cazul cel mai favorabil, în care vectorul de intrare era deja sortat, respectiv, cel mai defavorabil, în care vectorul de intrare era sortat în ordine inversă. În continuare, ne vom concentra, de regulă pe găsirea *timpului de execuție în cazul cel mai defavorabil*, cu alte cuvinte, a celui mai mare timp de execuție posibil relativ la orice date de intrare de dimensiune constantă n . Precizăm trei motive pentru această orientare:

- Timpul de execuție al unui algoritm în cazul cel mai defavorabil este o margine superioară a timpului de execuție pentru orice date de intrare de dimensiune fixă. Cunoscând acest timp avem o garanție că timpul nu va avea, niciodată, un timp de execuție mai mare. Nu va fi nevoie să facem presupuneri sau investigații suplimentare asupra timpului de execuție și să sperăm că acesta nu va fi, niciodată mult mai mare.
- Pentru anumiți algoritmi, cazul cel mai defavorabil apare destul de frecvent. De exemplu, în căutarea unei anumite informații într-o bază de date, cazul cel mai defavorabil al algoritmului de căutare va apare deseori când informația căutată nu este, de fapt, prezentă în baza de date. În anumite aplicații, căutarea unor informații absente poate fi frecventă.
- “Cazul mediu” este, adesea, aproape la fel de defavorabil ca și cazul cel mai defavorabil. Să presupunem că alegem la întâmplare n numere și aplicăm sortarea prin inserție. Cât timp va fi necesar pentru a determina locul în care putem insera $A[j]$ în subvectorul $A[1..j-1]$ sunt mai mici ca $A[j]$, și cealaltă jumătate sunt mai mari. Prin urmare, în medie, trebuie verificate jumătate din

elementele subvectorului $A[1..j-1]$, deci $t_j=j/2$. Dacă ținem seama de această observație, timpul de execuție mediu va apărea tot ca o funcție pătratică de n , la fel ca în cazul cel mai defavorabil.

În anumite cazuri particulare, vom fi interesați de *timpul mediu de execuție* al unui algoritm. O problemă care apare în analiza cazului mediu este aceea că s-ar putea să nu fie prea clar din ce sunt constituite datele de intrare “medii” pentru o anumită problemă. Adesea vom presupune că toate datele de intrare având o dimensiune dată sunt la fel de probabile. În practică această presupunere poate fi falsă, dar un algoritm aleator poate, uneori, să o forțeze.

2.3. Ordinul de creștere

Pentru a ușura analiza procedurii **Sortează – Prin - Inserție**, am utilizat mai multe presupuneri simplificatoare. În primul rând, am ignorat costul real al fiecărei instrucțiuni, folosind constantele c_i pentru a reprezenta aceste costuri. Apoi am observat că prin aceste constante obținem mai multe detalii decât avem nevoie în mod real: timpul de execuție în cazul cel mai defavorabil este de forma an^2+bn+c pentru anumite constante a, b, c care depind de costurile c_i ale instrucțiunilor. Astfel am ignorat nu numai costurile reale ale instrucțiunilor, dar și costurile abstracte c_i .

Vom face acum încă o abstractizare simplificatoare. Ceea ce ne interesează de fapt, este *rata de creștere* sau *ordinul de creștere* a timpului de execuție. Considerăm, prin urmare, doar termenul dominant al formulei (adică an^2) deoarece ceilalți termeni sunt relativ ne semnificativi pentru valori mari ale lui n . Ignorăm, de asemenea, și factorul constant c , deoarece pentru numere foarte mari, factorii constanți sunt mai puțin semnificativi decât rata de creștere în determinarea eficienței computaționale a unor algoritmi. Astfel, vom spune, de exemplu, că sortarea prin inserție are un timp de execuție în cazul cel mai defavorabil de $\theta(n^2)$ (pronunțat *teta de pătrat*). Vom folosi notația de tip θ în acest capitol cu caracter informal; va fi definită cu precizie în capitolul 2.

În mod uzual, vom considera un algoritm ca fiind mai eficient decât altul dacă timpul său de execuție în cazul cel mai defavorabil are un ordin de creștere mai mic. Această evaluare ar putea fi incorectă pentru date de intrare de dimensiune mică, dar în cazul unor date de intrare de dimensiuni foarte mari, un algoritm de tipul $\theta(n^2)$, de exemplu, va fi executat în cazul cel mai defavorabil mult mai repede ca unul de tipul $\theta(n^3)$.