

INSTITUTUL POLITEHNIC TIMISOARA  
FACULTATEA DE ELECTROTEHNICA

AUREL PUSCA

T E Z A D E D O C T O R A T


STUDIUL ANOMALIEI DIMENSIUNII DE PAGINA  
IN CADRUL UNUI SISTEM IERARHIC DE MEMORII

BIBLIOTECA CENTRALĂ  
UNIVERSITATEA "POLITEHNICA"  
TIMIȘOARA

CONDUCATOR ȘTIINȚIFIC

Prof. univ. dr. AL ROGOJAN

T i m i ș o a r a  
1978





## C U P R I N S

Cap.1. INTRODUCERE	pag.
1. Obiectul lucrării	1
2. Prezentarea generală a lucrării	2
Cap.2. SISTEME IERARHICE DE MEMORII	
1. Generalități	17
2. Obiective ale unui sistem ierarhic de memorii	18
3. Parametrii principali ai unui sistem ierarhic de memorii	22
3.1. Tehnologia de bază	24
3.2. Configurația	25
3.3. Comportarea de acces a programului	25
3.3.1. Spațiul numelor	26
3.3.2. Proces	35
3.4. Algoritm	38
4. Indicatori de performanță	44
4.1. Proporția succeselor. Proporția eșecurilor.	45
4.2. Timp acces efectiv. Cost efectiv.	47
5. Evaluarea și optimizarea I.L.V.M.	48
5.1. Simulare	48
5.1.1. Tehnici de eșantionare	50
5.1.2. Tehnici de tratare pe principiul stivei	51
5.2. Modelare matematică	53
5.2.1. Probleme de optimizare de programare nelineară	53
5.2.2. Utilizarea modelelor cu șiruri de așteptare.	55
6. Realizări și cercetări în I.L.V.M.	56
6.1. Sisteme cu memorie virtuală	58
6.1.1. Memorie virtuală paginată	59
6.1.1.1. Factori ce afectează perfor- manța unui sistem cu memorie virtuală paginată.	60
6.1.1.2. Căi de îmbunătățire a perfor- manței sistemului cu memorie virtuală paginată.	65
6.1.2. Memorie virtuală segmentată	69
6.2. Sisteme cache	71
6.3. Sisteme cu trei nivele	77

Cap.3. ANOMALIA DIMENSIUNII DE PAGINA	pag.
1. Alegerea dimensiunii paginii utilizate în cadrul unei I.L.V.M.	79
1.1. Fragmentarea memoriei	79
1.2. Eficiența operației de transport a paginii	82
1.3. Alte considerații privind dimensiunea paginii. Concluzii.	85
2. Anomalia dimensiunii de pagină.	89
3. Considerații finale. Necesitatea unor studii suplimentare.	99
Cap.4. MODELE ANALITICE ALE COMPORTARII DE ACCES A UNUI PROGRAM	
1. Modele existente	102
1.1. Funcția de timp de existență.	102
1.2. Modelul de grup de lucru	104
1.3. Modele stochastice	108
1.3.1. Model cu probabilități constante	108
1.3.2. Model markovian staționar	110
1.4. Critica modelelor prezentate	111
2. Modelul propus al comportării de acces a programului	112
2.1. Efectele lungimii ciclului de program asupra numărului defectelor de pagină	113
2.2. Considerații preliminare privind numărul de defecte de pagină.	115
2.3. Efectele paginării anterioare	117
2.4. Considerarea repartiției lungimii ciclurilor	120
2.5. Elaborarea modelului final	123
2.6. Validarea modelului elaborat	131
2.6.1. Proprietățile funcției DPA	132
2.6.1.1. Proprietatea 1	134
2.6.1.2. Proprietatea 2	140
2.6.1.3. Proprietatea 3	141
2.6.2. Verificări experimentale	143
Cap.5. STUDIUL ANOMALIEI DIMENSIUNII DE PAGINA	
1. Cercetarea anomaliilor dimensiunii de pagină cu ajutorul modelului elaborat	147
2. Comportarea localizată a unui program	152
2.1. Definiție și justificare	152

	pag.
2.2. Tipuri de localizare a com- portării de acces a programului	155
2.3. Localizarea și algoritmi de înlocuire	155
3. Interpretare cu caracter general a anomaliei dimensiunii de pagină	157
Cap.6. PREVENIREA APARIȚIEI ANOMALIEI DIMENSIUNII DE PAGINA	
1. Cercetarea șirului de referiri de pagină	159
2. Modificarea algoritmilor de înlocuire uzuali pentru prevenirea apariției anomaliei dimensiunii de pagină	162
3. Exemple de utilizare a unor algoritmi de înlocuire modificați	163
3.1. Algoritm LRU modificat	163
3.2. Algoritm FIFO modificat	166
4. Eficiența algoritmilor modificați	168
5. Perspective	171
Cap.7. CONCLUZII	172
Bibliografie	175



## CAP.1. INTRODUCERE

Programul Partidului Comunist Român de făurire a societății socialiste multilateral dezvoltate și înaintare a României spre comunism, adoptat de Congresul al XI-lea al P.C.R., prevede în "Obiectivele fundamentale ale etapei următoare a istoriei României socialiste" că în anii următori "electrotehnica și îndeosebi electronica vor cunoaște o puternică dezvoltare. Va trebui asigurată producerea în țară a mijloacelor de calcul, de automatizare și conducere necesare activității economice și de producție. "

"Orientările generale cu privire la întocmirea planului cincinal de dezvoltare economico-socială a României în perioada 1981-1985", adoptate de Conferința Națională a PCR din 7-9 decembrie 1977, prevăd că "în industria electronică se va urmări asimilarea și dezvoltarea producției de noi tipuri de calculatoare electronice, inclusiv echipamentele periferice aferente".

În acest cadru general se înscriu și cercetările legate de proiectarea, realizarea și utilizarea unor sisteme de memorii performante pentru calculatoarele electronice.

### 1. Obiectul lucrării

Scopul acestei lucrări este de a cerceta o problemă de interes apărută în gestiunea automată a ierarhiilor de memorii și anume anomalia dimensiunii de pagină. Cercetarea, realizată cu ajutorul unui model original al comportării de acces a unui program, stabilește cauzele apariției acestei anomalii și, pe această bază, propune o procedură de evitare a apariției anomaliei.

Prin ierarhie de memorii înțelegem o organizare de diferite tipuri de dispozitive de memorii cu scopul obținerii unui sistem de memorizare cu performanțe înalte, dar cu preț scăzut.

Un interes deosebit, teoretic și practic, prezintă ierarhiile lineare verticale de memorii (ILVM). În cadrul unei asemenea ierarhii ILVM dispozitivele de memorii sînt dispuse în

ordine crescătoare a timpurilor de acces și a capacităților, pot comunica unele cu altele dacă sînt situate pe nivele vecine și numai primul nivel al ierarhiei poate comunica cu unitatea centrală de prelucrare (UCP).

Cercetarea problemelor legate de proiectarea și gestiunea automată a acestor ierarhii de memorii a devenit în ultimii ani o direcție de interes major în preocupările legate de elaborarea unor sisteme de memorii mai rapide, cu capacități mai mari și mai economice. Importanța cercetării în domeniul sistemelor ierarhice de memorii este menționată și subliniată de numeroși cercetători. Astfel, a devenit un fapt acceptat că folosirea algoritmilor de gestiune automată a sistemelor de memorii, construite din cîteva nivele cu diferite timpuri de acces, a condus la o simplificare semnificativă a efortului de programare. Deși există pînă în prezent mai multe implementări a unor sisteme de memorii cu mai multe nivele, gestiunea automată a unor asemenea sisteme este un domeniu insuficient cercetat. De exemplu, în elaborarea unor algoritmi eficienți de gestiune a unei ierarhii de memorii, precum și în previziunea performanței unei asemenea ierarhii au rămas unele probleme încă neclarificate.

Una din problemele apărute în domeniul gestiunii unei ierarhii de memorii și care pînă în prezent nu a făcut obiectul unei cercetări analitice este anomalia dimensiunii de pagină. Cercetarea acestei probleme, stabilirea cauzei apariției anomaliai și elaborarea unei proceduri de evitare a apariției acesteia sînt realizate în lucrarea prezentă.

Din punct de vedere al organizării lucrarea este împărțită în 6 capitole. Structura ei poate fi expusă prezentînd pe scurt, în cele ce urmează, conținutul acestor capitole.

## 2. Prezentarea generală a lucrării

2.1. Capitolul 1, de introducere, precizează obiectul lucrării. În continuare se face o prezentare generală a conținutului lucrării și a contribuțiilor originale aduse în ea de autor.



2.2. Capitolul 2 este o minimonografie dedicată problemelor majore ale studiului legat de sistemele ierarhice de memorii. Scopul lui este de a introduce noțiunile de bază în analiza ierarhiilor de memorii și de a prezenta situația la zi în problemele de analiză, proiectare și realizare a unor asemenea sisteme.

Astfel, se arată obiectivele realizării unui sistem ierarhic de memorii: obținerea unor indicatori cost/performanță avantajoși; simplificarea și automatizarea programării (un sistem de gestiune automată a unei ierarhii de memorii preia multe sarcini ce reveneau programatorilor, mărind astfel productivitatea muncii acestora); crearea posibilităților de utilizare a noilor tipuri de dispozitive de memorii și extinderea domeniului aplicațiilor; studiul comportării de acces a programelor și al comportării sistemelor de calcul.

Se cercetează apoi parametrii principali ai unui sistem ierarhic de memorii și anume: tehnologia de bază, configurația, comportarea de acces a programului și algoritmi utilizați în transferul de informații între nivelele ierarhiei.

UCP, sub controlul programului, produce o serie secvențială de referiri la sistemul de memorii. Aceste referiri ale procesorului se fac la adrese logice (nume ce servesc pentru a identifica în mod unic fiecare unitate individuală de informații memorate, indiferent de localizarea ei în cadrul ILVL). Secvența în timp a referirilor la adrese logice este denumită șirul de referiri.

Unitatea standard de memorare a informațiilor și de transfer între nivelele vecine ale ierarhiei de memorii este pagina. Secvența în timp a referirilor procesorului la pagini logice este denumită șirul de referiri de pagină.

Programul unui utilizator împreună cu datele aferente sînt încărcate în nivelul inferior al unei ILVL; pe măsura executării programului pagini individuale de instrucții și/sau de date sînt transferate spre partea superioară a ierarhiei, ajungînd în primul nivel, singurul care comunică cu unitatea centrală de prelucrare. Secvența combinată de adrese de instrucții și de adrese de date, secvență generată de către program, definește comportarea de acces la memorii a programului.

Gestiunea unei ierarhii de memorii are rolul de a decide cum trebuie organizată informația în cadrul ierarhiei între nivelele acestora și în cadrul fiecărui nivel și a decide când să se transfere informația între nivelele ierarhiei. Algoritmii utilizați în transferul de pagini între nivelele ierarhiei operează în sfera de aducere-plasare a paginilor (localizează în cadrul ierarhiei o pagină adresată de CPU și a aduce în primul nivel) și în sfera de înlocuire-replasare a paginilor (înlocuiește o pagină din primul nivel al ierarhiei). Problema majoră nu este de a decide ce pagină trebuie să fie adusă, ci de a decide ce pagină trebuie să fie înlocuită. Regula utilizată pentru a decide ce pagină trebuie înlocuită este numită algoritmul înlocuirii. Situația în care într-un nivel carecarea al ierarhiei este adresată o pagină ce nu se găsește în acel nivel este denumită defect de pagină și are ca consecință întârzierea de către sistemul de gestiune automată a ierarhiei a acțiunii de aducere a paginii cerute din nivelul inferior al CPU în care aceasta este dispusă.

În continuare se introduce indicatorii de performanță ai unui sistem ierarhic de memorii: proporția succeselor (raportul dintre numărul de referiri de pagină satisfăcătoare și numărul total al referirilor de pagină în cadrul unui anumit nivel), proporția eșecurilor (raportul dintre numărul de defecte de pagină și numărul total al referirilor de pagină în cadrul unui anumit nivel), timpul de acces efectiv și costul efectiv.

Evaluarea și optimizarea unor sisteme ierarhice de memorii se pot realiza cu tehnici diferite de simulare și modelare matematică. Simularea este utilizată în situațiile în care nu sînt disponibile tehnici analitice; ea asigură rezultate a căror exactitate depinde de gradul de detaliere cu care este realizată; de obicei este costisitoare. Modelarea matematică în studiul ierarhiilor de memorii se utilizează în situațiile în care se urmărește în special o înțelegere calitativă a modului în care sistemul este afectat de variațiile diferiților parametri; ea conduce la rezultate de

obicei mai puțin precise ca în cazul simulării.

Dintre tehnicile de simulare sînt discutate cele de eşanționare și de tratare pe principiul stivei, iar tehnicile de modelare matematică sînt exemplificate prin utilizarea programării neliniare și a modelelor cu șiruri de așteptare.

În continuare sînt comentate unele realizări și cercetări în domeniul ierarhiilor de memorii.

Astfel sînt analizate unele sisteme cu memorie virtuală paginată și segmentată. În cadrul sistemelor cu memorie virtuală paginată se cercetează factorii ce afectează performanța unui asemenea sistem: viteza și numărul dispozitivelor de paginare, viteza unității centrale de prelucrare, capacitatea memoriei reale, capacitatea memoriei virtuale. În continuare sînt arătate căile de îmbunătățire a acestei performanțe, care sînt: selectarea judicioasă a proporției între capacitatea memoriei reale și capacitatea memoriei virtuale, ținînd seama de viteza de calcul a UCP; selectarea unei dimensiuni de pagină corespunzătoare capacității sistemului de operare; utilizarea unui număr sporit și mai rapid de dispozitive de paginare; utilizarea unui cod ce nu se modifică pe el însuși; utilizarea unor memorii tampon de I/E mai mari; structurarea programelor de aplicații; alocarea unei anumite capacități de memorie reală în cadrul aplicațiilor în prelucrarea pe loturi; utilizarea unui algoritm de planificare a priorităților; utilizarea unor proceduri de paginare fracționată; utilizarea în cadrul sistemului a mai multor dimensiuni distincte de pagină. În încheierea capitolului sînt cercetate sisteme realizate pe baza unor ILVM cu două și trei nivele.

2.3. În capitolul 3 este prezentată anomalia dimensiunii de pagină.

Dimensiunea paginii este un parametru important al unei ierarhii de memorii, afectînd în mod direct performanța acesteia. Din acest motiv s-a acordat o atenție deosebită determinării dimensiunii optime de pagină. S-a constatat că factorii principali ce influențează alegerea dimensiunii de pagină sînt fragmentarea memoriei și eficiența operației de transport a paginii. Prin fragmentarea memoriei se înțelege împărțirea memoriei disponibile într-un număr mare de domenii libere, separate prin do-

menii ocupate. Acest fenomen este de natură statistică și apare în situația în care domenii de memorie de dimensiuni variabile sînt ocupate și apoi eliberate de diverse rutine, după intervale variabile de timp. Fragmentarea memoriei conduce la scăderi în utilizarea acesteia, căci apar situații în care fiecare din domeniile libere disponibile este prea mic pentru a satisface o cerere de spațiu de memorie, deși suma capacităților domeniilor libere este suficientă. Utilizarea memoriei este măsurată prin procentul din capacitatea totală a memoriei a capacității memoriei ocupate de către cererile satisfăcute de spațiu de memorie. O problemă de interes deosebit cercetată a fost efectul asupra utilizării memoriei a rotunjirii cererilor de memorie la un multiplu întreg al unității de alocare (pagini). S-a constatat astfel că prin mărire a paginii utilizarea memoriei scade. Acest efect se datorează faptului că pe măsura creșterii dimensiunii paginii și datorită rotunjirii cererii de memorie se mărește de asemenea partea din spațiul de memorie alocat și nefolosit (deci irosit).

Timpul necesar pentru a realiza transportul unei pagini între două nivele vecine ale unei ILVM este format din timpul mediu de acces și din timpul de transfer.

Timpul mediu de acces al unui dispozitiv de memorie este valoarea medie a timpului consumat de acest dispozitiv de memorie între momentul primirii unei adrese fizice de înregistrare a unei unități informaționale și momentul în care această unitate informațională devine disponibilă. Timpul de transfer al unei pagini între două nivele vecine ale unei ILVM este determinat de dimensiunea paginii și de rata de transfer cu valoare mai mică a dispozitivului de memorie situat pe nivelul mai inferior în cadrul ierarhiei.

La dispozitivele de memorie ce intră în componența unei ILVM timpul de acces variază considerabil mai mult decât variază rata de transfer. Această situație pune problema avantajelor posibile de obținut (respectiv un timp mediu mai mic de transport al paginilor între nivelele ierarhiei) prin transferul în cadrul unui singur acces, a unui volum sporit de informații sau, cu alte cuvinte, în cadrul utilizării unei

dimensiuni mărite de pagină. S-a cercetat creșterea timpului de transport în cazul transferului unei pagini de dimensiune dublă  $2p$  față de timpul de transport al unei pagini de dimensiune  $p$  constatându-se că această creștere este substanțială în cadrul transferurilor între nivelele superioare ale ierarhiei, caracterizate prin timpi rapizi de acces și este mică pentru nivelele inferioare ale ierarhiei, caracterizate prin timpi lenți de acces. Astfel, datorită creșterii mari a timpului de transport, pentru dispozitivele de memorii cu timpi rapizi de acces utilizarea unei pagini de dimensiune mărită nu creează avantaje considerabile; în cazul însă al dispozitivelor de memorii cu timpi lenți de acces, datorită creșterii mici a timpului de transport, utilizarea unei pagini de dimensiune mărită este avantajoasă. Introducerea recentă în cadrul ierarhiilor de memorii a unor noi tehnologii de dispozitive de memorii (memorii CCD - bazate pe dispozitive cu transfer de sarcină, memorii bubble - cu bule magnetice și altele) cu timpi rapizi de acces reduce drastic avantajele posibile ale utilizării unor dimensiuni mari de pagină.

Pe baza analizei factorilor implicați în alegerea dimensiunii de pagină se trage concluzia că utilizarea unor pagini de dimensiuni mici în cadrul sistemelor de calcul moderne bazate pe ILVM conduce la îmbunătățiri în gestiunea sistemului de memorii. Aceste îmbunătățiri se referă la utilizarea mai eficientă a spațiului de memorie și la valoarea mică a consumului neproductiv de timp utilizat pentru accesul hardware și gestiunea software a paginilor.

În continuare este definită situația de anomalie a dimensiunii de pagină. În acest scop vom considera execuția unui program în cadrul unei ILVM în două situații distincte, caracterizate prin utilizarea unor dimensiuni diferite de pagină  $p_1$  și  $p_2$  astfel ca

$$p_2 = \frac{p_1}{k}$$

unde, de obicei,  $k = 2^i$ ,  $i = 1, 2, \dots$

Situația de anomalie a dimensiunii de pagină apare în cazul în care numărul defectelor de pagină generate la execuția programului și utilizarea unei pagini de dimensiune mai mică  $p_2$

va fi de peste  $k$  ori mai mare decât numărul defectelor de pagină generate la execuția aceluiasi program și utilizarea unei pagini de dimensiune  $p_1$ . Numărul mare de defecte de pagină, sau, cu alte cuvinte, activitatea exagerată de paginare observată în cazul utilizării unei pagini de dimensiuni reduse  $p_2$ , are ca efect creșterea consumului neproductiv de timp utilizat pentru accesul hardware și gestiunea software a paginilor. Deci, deși în general utilizarea unor dimensiuni mici de pagină aduce îmbunătățiri în utilizarea sistemului de memorii, în cazul apariției situației de anomalie a dimensiunii de pagină se constată o scădere a performanței (consum mare de timp neproductiv). Anomalia dimensiunii de pagină a fost constatată și descrisă, dar nici o lucrare nu a fost dedicată studiului acestei probleme și clarificării factorilor implicați în ea. În consecință lipsește o înțelegere precisă a mecanismului de apariție a acestei anomalii. În aceste condiții rezultă necesitatea unor studii suplimentare în această direcție. Importanța unor asemenea studii rezultă din faptul că pe baza cunoașterii mecanismului de apariție a acestei anomalii se vor putea elabora metode sau proceduri de prevenire a anomaliei. Aceste metode și proceduri vor avea un interes practic imediat. Ele vor permite obținerea unor îmbunătățiri suplimentare în utilizarea unui sistem ierarhic de memorii prin folosirea unor dimensiuni reduse de pagină, fără riscul apariției unei activități exagerate de paginare.

2.4. În capitolul 4, cu scopul de a crea un instrument care să poată fi utilizat în cercetarea anomaliei dimensiunii de pagină, este elaborat un model analitic al comportării de acces a unui program într-un mediu cu memorie virtuală. Elaborarea acestui model a fost necesară deoarece nici unul din modelele analitice ale comportării de acces a unui program descrise în literatură nu poate fi folosit în scopul urmărit de noi, întrucât aceste modele nu iau în considerare variația dimensiunii de pagină.

Capitolul debutează prin analiza critică a modelelor analitice de bază ale comportării de acces a unui program studiate pînă în prezent în literatură.

Astfel în cazul funcției de timp de existență, care stabilește o relație între lungimea medie a intervalelor de execuție (între defecte succesive de pagină) și dimensiunea memoriei alocate programului pentru desfășurare, se constată că modelul este valid pentru programe reale numai pe o porțiune a domeniului de variație a alocării memoriei și că parametrii acestui model nu sînt în mod clar definiți pe baza proprietăților programului care este modelat.

În privința modelului de grup de lucru, care este bazat pe recunoașterea comportării localizate a programelor (prin comportare localizată înțelegînd faptul că în decursul oricărui interval de execuție programul favorizează, în mostra lui de referiri la memorie, unele din paginile lui într-o măsură mai mare decît pe altele) se constată dificultatea de a măsura dinamic parametrul de grup de lucru, cu scopul de a estima dimensiunea grupului de lucru; de asemenea modul cum este definită dimensiunea grupului de lucru nu permite includerea paginilor care sînt adresate o singură dată. În continuare sînt analizate critic cîteva modele stochastice, ce se referă la reprezentarea analitică a șirului de referiri de pagină a unui program: modelul cu probabilități constante și modelul markovian staționar. Astfel se constată că modelul ce presupune probabilități constante de referire a paginilor sau probabilități constante de tranziție între pagini impune un grad de simplificare prea mare al comportării de acces a unui program, iar modelul ce utilizează proprietățile unui proces semi-Markov conduce la necesitatea estimării unui număr mare de parametri, care nu pot fi puși în legătură directă cu proprietățile programului modelat. În această situație pentru analiza anomaliei dimensiunii de pagină apare necesitatea elaborării unui instrument de cercetare corespunzător, în cazul de față un model al comportării de acces a unui program, care să ia în considerație și efectul variației dimensiunii de pagină, iar parametrii lui să fie în mod clar definiți pe baza proprietăților programului care este modelat.

În cele ce urmează, ținînd seama de cele de mai sus, este elaborat un model analitic al comportării de acces a unui program într-un mediu cu memorie virtuală, model ce presupune următoarea comportare de acces a programului:

- (1) selectarea aleatoare a unei locații "a" în spațiul de adrese virtuale al programului;
- (2) selectarea aleatoare a unui ciclu cu lungimea  $d$ ;
- (3) accesul la  $d$  locații în ciclul (2) de mai sus secvențial de 6 ori;
- (4) repetarea pașilor de mai sus.

Deci, în conformitate cu cele de mai sus, comportarea de acces a programului constă în apelarea unei serii de cicluri, poziția și dimensiunea cărora se schimbă în mod aleator.

Se urmărește apoi a se determina numărul defectelor de pagină generate de un program cu o asemenea comportare de acces. În acest scop, se cercetează efectul asupra numărului defectelor de pagină a următorilor factori:

- lungimea ciclului de program;
- paginarea anterioară apelării ciclului curent;
- repartiția lungimii ciclurilor; pentru aproximarea repartiției lungimii ciclurilor este utilizată repartiția de tipul  $\Gamma$  care permite o deosebită flexibilitate în controlul asupra formei curbei ce reprezintă funcția de densitate de repartiție a lungimii ciclurilor.

În acest mod în lucrare se obține o expresie analitică pentru funcția ce determină valoarea medie a numărului de defecte de pagină, care apar în decursul execuției unui program într-un mediu cu memorie virtuală.

Modelul elaborat este verificat prin faptul că, pe baza lui, se regăsesc pe cale analitică:

- (1) caracteristicile calitative ale funcției ce determină numărul defectelor de pagină generate la execuția unui program, caracteristici observate în cadrul unor studii publicate de simulare;
- (2) rezultatele numerice experimentale.

Studii publicate de simulare au stabilit, pe baza analizei unor șiruri de referiri de pagină generate în cadrul execuției unor programe reale, următoarele 3 caracteristici ale funcției ce determină numărul defectelor de pagină gene-



rate la execuția unui program:

(a) această funcție este o funcție concavă în dependența de numărul de instrucții executate;

(b) această funcție are o asimptotă pentru valori mari ale numărului de instrucții executate;

(c) numărul de instrucții executate de program între defecte succesive de pagină crește cu numărul de pagini acumulate de program.

În lucrare aceste 3 caracteristici sînt stabilite analitic, pe baza expresiei obținute pentru funcția ce determină valoarea medie a numărului de defecte de pagină ce apar la execuția unui program.

În privința verificării rezultatelor numerice obținute cu ajutorul modelului s-au folosit unele rezultate experimentale publicate (există raportate în literatură numeroase rezultate experimentale privind comportarea de acces a unor programe într-un mediu cu memorie virtuală; rezultatele folosite de noi sînt acceptate unanim ca semnificative). Pentru programele pentru care avem deja la dispoziție rezultate numerice experimentale s-au calculat cu ajutorul modelului, folosind expresia analitică ce determină valoarea medie a numărului defectelor de pagină și utilizînd un program pe care l-am denumit GAMINC, valorile pentru numărul defectelor de pagină generate în cadrul execuției acestor programe. Pe baza comparării rezultatelor numerice experimentale publicate în mai multe lucrări cu cele determinate analitic cu ajutorul modelului propus se constată o bună concordanță. În acest mod se dovedește că modelul propus dă rezultate corecte.

2.5. În capitolul 5 se cercetează anomalia dimensiunii de pagină cu ajutorul modelului elaborat în capitolul precedent. Anume, pe baza expresiei analitice obținute se calculează valoarea medie DPA a numărului de defecte de pagină care apar în decursul execuției unui program și utilizării succesive a două dimensiuni de pagină  $p$  și, respectiv,  $p/k$ .

Fie aceste valori DPA ( $p$ ) și DPA ( $p/k$ ).

Situația de anomalie a dimensiunii de pagină apare în cazul în care numărul defectelor de pagină generate la execuția programului și utilizarea unei pagini de dimensiune  $p/k$  va fi

de peste  $k$  ori mai mare decât numărul defectelor de pagină generate la execuția aceluiași program și utilizarea unei pagini de dimensiune  $p$ , adică

$$DIF = DPA \left( \frac{p}{k} \right) - k \cdot DPA(p) > 0$$

Pornind de la expresia pentru  $DPA(p)$  obținută în capitolul 4, se obține pentru  $DIF$  o expresie analitică relativ simplă, ce permite identificarea posibilităților de apariție a situațiilor de anomalie a dimensiunii de pagină.

Pentru a interpreta sensul rezultatului analitic obținut se definește comportarea localizată a unui program într-un mediu cu memorie virtuală. Prin această comportare localizată se înțelege faptul că programul în decursul unui anumit interval de execuție, favorizează (în cadrul șirului lui de referiri de pagină), unele din paginile lui într-o măsură mai mare decât pe altele. Factorii care conduc la această comportare sînt: fluxuri de instrucții secvențiale, modularitatea funcțională, organizarea datelor înrudite după conținut, ciclurile, modul de programare. Se cercetează apoi tipurile de comportare localizată a unui program și anume localizarea temporală și cea spațială. Pe baza acestor tipuri de comportare localizată a unui program se introduce conceptul de localizare, cu caracter general, spațio-temporală. Se cercetează apoi modul cum diferiți algoritmi de înlocuire iau în considerație localizarea temporală și cea spațială. Se constată că algoritmi uzuali de înlocuire se preocupă mult de aspectele temporale ale mostrei de referiri a programului la spațiul adreselor. Aspectele spațiale sînt tratate ca un produs secundar, prin faptul că algoritmi de înlocuire aduc în memoria principală, la un moment dat, o pagină întreagă, adică o regiune spațială.

Tinînd seama de acest mod în care sînt luate în considerație localizarea temporală și spațială a programelor de către algoritmi de înlocuire uzuali, se constată că micșorarea dimensiunii de pagină conduce la creșterea performanței (mărirea valorii proporției succeselor) algoritmilor de înlo-

cuire în cazul unui program caracterizat printr-o comportare localizată pronunțat temporală și la scăderea performanței (micșorarea valorii proporției succesei) în cazul unui program caracterizat printr-o comportare localizată pronunțat spațială. Acest lucru este o urmare a faptului că, prin micșorarea dimensiunii de pagină (în cadrul unei alocări date în  $M_1$ ), în nivelul  $M_1$  al ILVM se va realiza o colecție mai variată de porțiuni de program, deși fiecare din ele mai mică ca dimensiune. Acest tip de colecție poate favoriza un program cu referiri dispersate și grupate la spațiul adreselor, ca urmare a unui caracter temporal al comportării sale de acces. Pe de altă parte însă, micșorarea dimensiunii de pagină defavorizează un program ce are o comportare de localizare spațială căci, prin micșorarea dimensiunii paginii, se micșorează și numărul de adrese ce pot fi apelate succesiv în cadrul aceleiași pagini. Se subliniază faptul că algoritmi de înlocuire trebuie să ia în considerare ambele tipuri de comportare localizată a programelor: atât temporală, cât și spațială. În final, pe baza conceptului de localizare spațio-temporală, se dă o interpretare cu caracter general rezultatului analitic obținut în cercetarea anomaliei dimensiunii de pagină și anume că situația de anomalie poate apărea în cazul acelor programe sau secțiuni de program caracterizate printr-o slabă localizare temporală și o pronunțată localizare spațială.

2.6. Capitolul 6 are ca obiect studiul prevenirii apariției anomaliei dimensiunii de pagină. Elaborarea unor măsuri care să prevină apariția acestei anomalii este realizată prin cercetarea mai în detaliu a mecanismului prin care comportarea de acces a programului conduce la apariția anomaliei, respectiv prin cercetarea șirului de referiri de pagină. Această cercetare ne-a condus la identificarea situațiilor de apariție a anomaliei dimensiunii de pagină. Pe baza identificării acestor situații, în lucrare se propune o procedură de modificare a algoritmilor de înlocuire, care realizează prevenirea apariției anomaliei.

Această procedură constă în următoarele:

(1) paginile programului în cauză se organizează în grupe, mărimea cărora corespunde unei dimensiuni mărite de pagină; o asemenea grupă este numită pagină-martor;

(2) algoritmi de înlocuire uzuali se aplică la ansamblul paginilor unei grupe.

Se consideră situațiile în care algoritmul de înlocuire operează (a) asupra mulțimii paginilor programului și în paralel- (b) asupra mulțimii paginilor-martor. Procedura propusă evită faptul ca, la un moment dat în desfășurarea unui program, o pagină carecure A a acestuia să fie înlocuită dintr-un nivel al ierarhiei (în cadrul situației a de mai sus), dacă, în același moment al desfășurării programului, pagina-martor din care pagina A face parte nu a fost și ea înlocuită din același nivel (în cadrul situației b). Condiția ca o pagină a unei grupe să nu poată fi înlocuită dintr-un nivel al ierarhiei, dacă pagina-martor corespunzătoare nu a fost și ea înlocuită din același nivel, poate fi realizată în diferite moduri, care sînt discutate în lucrare.

Modul de aplicare al acestei proceduri este exemplificat în cazul unor algoritmi de înlocuire cunoscuți, dar modificați conform procedurii descrise: anume, în lucrare se dau exemple de aplicare a algoritmilor LRU și FIFO modificați. Se constată, în cazul șirurilor de referiri de pagină considerate:

(1) aplicarea algoritmilor LRU și FIFO nemodificați conduce la apariția anomaliei dimensiunii de pagină;

(2) aplicarea algoritmilor LRU și FIFO modificați previne apariția anomaliei.

În acest context se discută unele aspecte legate de aplicarea algoritmilor modificați asupra ordonării paginilor.

În continuare se analizează eficiența aplicării algoritmilor modificați. Se stabilește că procedura de modificare a algoritmilor de înlocuire fixează o limită superioară pentru numărul defectelor de pagină în regiunea de referire densă a programului la memorie, fără a micșora valoarea proporției succeselor în regiunile cu referiri rară și moderată. Astfel, utilizarea acestei proceduri creează posibilitatea ca să se obțină îmbunătățiri suplimentare în gestiunea unui sistem ierarhic de memorie prin utilizarea unor dimensiuni reduse de pagină, fără riscul unui consum mare de timp neproductiv datorat activității exagerate de paginare, procedura propusă evitînd apariția anomaliei dimensiunii de pagină.

În încheierea capitolului sînt expuse unele probleme, legate de cele tratate în lucrare, cercetarea cărora ar prezenta interes în perspectivă:

- studiul și elaborarea unor algoritmi de înlocuire, care să ia în considerație comportarea de localizare spațială a programelor;

- studiul relației algoritmilor modificați prin procedura propusă cu alți algoritmi de înlocuire;

- cercetarea eficienței algoritmilor modificați prin studii suplimentare (prin simulare și măsurători directe efectuate în cadrul unei ierarhii de memorii).

2.7. În capitolul 7, de concluzii, după sublinierea interesului teoretic și practic al rezolvării problemei cercetate în lucrare, a anomaliei dimensiunii de pagină, în cadrul general al problemelor legate de gestiunea automată a ierarhiilor de memorii, se prezintă contribuțiile originale aduse în cadrul acestei lucrări de autor. Astfel, contribuțiile originale mai importante se referă la:

- elaborarea unui model analitic al comportării unui program operînd într-un mediu cu memorie virtuală, prin obținerea unei expresii analitice pentru funcția ce determină valoarea medie a numărului de defecte de pagină, ce apar în decursul execuției unui program într-un mediu cu memorie virtuală;

- stabilirea proprietăților funcției ce determină valoarea medie a numărului defectelor de pagină, ce apar în cadrul execuției unui program într-un mediu cu memorie virtuală;

- studiul analitic, cu ajutorul modelului elaborat al comportării de acces a programului, a situațiilor de apariție a anomaliei dimensiunii de pagină;

- introducerea conceptului de comportare localizată spațio-temporală și interpretarea cu caracter general, pe baza acestui concept, a apariției anomaliei dimensiunii de pagină;

- identificarea mecanismului de apariție a anomaliei dimensiunii de pagină pe baza cercetării șirului de referiri de pagină a programului;

- elaborarea unei proceduri de prevenire a apariției anomaliei dimensiunii de pagină și descrierea modului ei de aplicare - modificarea corespunzătoare a algoritmilor de înlocuire uzuali și modul lor de operare;

- studiul eficienței algoritmilor modificați prin procedura propusă și precizarea unor perspective de interes în domeniu.

✱

✱

✱

Realizarea prezentei lucrări a fost posibilă sub îndrumarea permanentă a prof.dr.ing. Al.Rogojan, conducătorul științific al lucrării, căruia autorul îi exprimă pe această cale profunde mulțumiri pentru întreaga activitate de îndrumare științifică și metodologică oferită.

Autorul exprimă de asemenea mulțumirile sale prof. D. Ferrari, dr.M. Kobayashi și dr.E. Lau (EECS - Universitatea Berkeley - SUA) și ing.C. Mașek (ITC - București) pentru discuțiile foarte utile avute asupra unor probleme din lucrare.

## CAP.2. SISTEME IERARHICE DE MEMORII

### 1. Generalități.

Evoluția sistemelor de calcul a fost marcată de o cerere în continuă creștere pentru dispozitive de memorii mai rapide, cu capacități mai mari și mai economice. Accentul principal în această evoluție a fost pus pînă în prezent pe tehnologia hardware, însă, pe măsură ce sistemele de calcul au avansat, s-a manifestat un interes în creștere în problema de proiectare a sistemelor, ce realizează utilizarea cea mai performantă și cea mai eficientă a unor tehnologii hardware date.

O metodă importantă de obținere a unei utilizări eficiente a unor tehnologii hardware date este utilizarea ierarhiilor de memorii. Astăzi este un lucru recunoscut faptul că cerințele în conflict a unor memorii cu performanțe înalte, dar de cost scăzut, pot fi satisfăcute printr-o mixtură de tehnologii, combinînd dispozitive de memorii - DM costisitoare cu performanțe ridicate cu DM ieftine, cu performanțe scăzute. Acestei strategii i s-au atribuit diferite nume ca "sistem ierarhic de DM", "gestiunea automată a DM cu mai multe nivele", "memorie virtuală" și "sistem de memorie virtuală pentru gestiunea automată a unor ierarhii de DM cu mai multe nivele". O ierarhie de memorii a fost pentru prima oară implementată în sistemul de calcul elaborat la Universitatea din Manchester în Anglia în 1949.

Cercetările în domeniul tehnicilor automate pentru ierarhii de memorii pot fi datate în urmă cu cca. 15 ani, însă și în prezent sînt rămase nerezolvate sau insuficient înțelese multe probleme. Această situație poate fi parțial explicată prin faptul că aceste sisteme de ierarhii de memorii tind să fie:

- foarte complexe;
- nepotrivite pentru majoritatea tehnicilor analitice convenționale;
- puternic influențate de tehnologia în rapidă evoluție a calculatoarelor.

./.

115.11  
207.01F  
220

## 2. Obiective ale unui sistem ierarhic de memorii.

Obiectivele propuse prin realizarea unui sistem ierarhic de DM se referă la:

(1) Obținerea unor indicatori cost/performanță avansați.

Pe măsură ce tehnicile de arhitectură și tehnologia calculatoarelor au avansat, a devenit posibilă realizarea unor sisteme de calcul cu viteze foarte mari. Aceste sisteme sînt evaluate în valori de MIPS (milioane de instrucții pe secundă). Există sisteme experimentale de peste 100 MIPS (ILLIAC IV și CDC - STAR). Unele sisteme convenționale de capacitate mare au atins limite de 5 sau 10 MIPS (CDC - 7600 sau IBM 370-195). S-a observat însă că strîns legate de viteza procesorului sînt cerințele de intrare/ieșire ale unui sistem convențional. Pe baza unor măsurători experimentale a fost postulat că în cadrul unui sistem de calcul se atinge în medie valoarea de 1 bit intrare/ieșire pentru fiecare instrucție executată. (Această valoare este des referită ca constanta lui Andahl(2)). Astfel, multe din sistemele de calcul de înaltă performanță au fost confruntate cu probleme dificile de "gîtuire" în domeniul intrare/ieșire, în special în cazul cînd aceste cereri tind să apară grupate în pachete. Un sistem ierarhic de memorii este util în această situație, reducînd considerabil dimensiunile acestei probleme.

La celălalt capăt al domeniului de capacități se pot constata progresele substanțiale realizate în ultimii ani de minicalculatoare (procesoare de cost redus). Termenul "mini" poate fi înșelător. Aceste procesoare sînt, în mod obișnuit, de sute de ori mai rapide decît calculatoarele comerciale timpurii, la o fracțiune de cost. Astfel, minicalculatoarele contemporane operează aproximativ 1 milion adunări de numere a 5 cifre pe secundă, în timp ce UNIVAC I (cca.1951) putea executa cca. 2000 adunări de numere a 12 cifre pe secundă. Datorită progreselor tehnologice și economiilor de proporții rezultate din producția de serie mare, unele minicalculatoare sînt oferite la prețuri mai mici de 2000 dolari, iar microcalculatoare realizate într-o singură pastilă sînt disponibile la prețuri în jur de doar 5 dolari (170). Impactul apariției acestor procesoare asupra sistemelor



de calcul este legat însă și de posibilitatea producerii unor dispozitive de memorii de mare capacitate și ieftine. Un procesor de 5 dolari nu este interesant dacă costul memoriilor este în domeniul zecilor de mii de dolari.

Prin dezvoltarea unui sistem eficace de ierarhii de memorii se poate avansa pe calea reducerii costurilor DM la nivelul acestor procesoare ieftine. Ca rezultat, un număr mare de soluții tehnice cunoscute, relative la problemele de tratare a informațiilor, vor deveni, în sfârșit, soluții economic convenabile.

## (2) Simplificarea și automatizarea programării.

Organizarea unui sistem ierarhic de memorii a unui calculator are un impact considerabil asupra arhitecturii programelor și eficienței programatorilor. Într-o mare măsură creșterea posibilă a productivității este obținută prin eliminarea sau reducerea limitărilor impuse în mod obișnuit de sistemele de memorii. Aceste restricții deseori abat programatorul, în măsura în care el alocă o cantitate substanțială de timp pentru a învinge limitările sistemului, în loc de a rezolva problema propriu-zisă. Astfel, în literatura de specialitate se remarcă faptul că conținutul de erori al unor programe este deseori dependent de disponibilul de capacitate de memorii. Dacă disponibilul este foarte limitat, autorii software-ului trebuie să recurgă la superpoziții și alte artificii de codificare pentru a comprima funcțiile dorite în spațiul de memorie alocat. Se presupune că aceste artificii introduc o mare complexitate și sînt locul multor erori. Acest efect este citat de proiectanții de calculatoare destinate navelor spațiale, unde alocarea unui alt bloc de memorie de 4 K este o decizie majoră de proiectare.

Mai precis, programatorul trebuie să se îngrijească de:  
a) eficiența codului limbajului de programare;

Dacă un compilator al unui limbaj evoluat tinde să producă programe care sînt considerabil mai mari decît cele produse de către un translator de nivel mai jos, poate deveni necesar să se folosească limbajul de nivel mai jos, pentru a economisi memorie. Această limitare este contrară faptului general acceptat că un limbaj de nivel înalt mărește productivitatea programării.

./.

b) dimensiunea programului;

Pentru o dimensiune specifică de memorie există programe care nu pot fi scrise ușor pentru a se încadra în această limitare de capacitate. Totuși programatorii încearcă deseori, dar cu eforturi considerabile.

c) structuri de date;

Programatorul este deseori confruntat cu necesitatea de a alege între o reprezentare a structurii de date care este convenabilă pentru folosire și o altă reprezentare care economisește memorie. Această economisire poate pretinde folosirea unei reprezentări a structurii de date incomode sau complicate.

d) caracteristici de echipamente specifice;

Dacă programatorul trebuie să obțină maximum-ul din sistemul de memorii avut la dispoziție, în ceea ce privește capacitatea și performanța, el poate recurge la tehnici care sînt particulare la dispozitivele de memorii respective. Dacă aceste dispozitive de memorii sînt schimbate, poate exista o influență considerabilă asupra software-ului.

Ierarhiile de memorii își propun să elimine, să automatizeze sau cel puțin să reducă considerabil problemele de programare descrise mai sus.

(3) Crearea posibilităților de utilizare a noilor tipuri de dispozitive de memorii și extinderea domeniului aplicațiilor.

Pînă nu demult, în utilizarea dispozitivelor de memorii a existat o tendință de a raporta aplicațiile la tehnologiile specifice disponibile. Aceasta a determinat faptul ca anumite domenii de aplicare să fie abandonate ca neconvenabile și multe strategii de gestiune a memoriilor să fie discreditate ca inaplicabile sau ineficiente. Cîteodată se au în vedere doar aplicațiile și tehnicile în uz și se evită sau se ignoră alternativele posibile și motivele care au dus la ocolirea acestor alternative.

În prezent sîntem martorii unei creșteri mari a interesului pentru aplicații și tehnologii. Necesitățile noilor aplicații se referă la dispozitive de memorii mai mari și mai rapide, la prețuri mai mici.

Noi direcții în domeniul tehnologiei pentru dispozitive de memorii, ca și unele considerații de ansamblu asupra acestui

domeniu și perspectivele lui, fac obiectul a numeroase lucrări și studii. Astfel Bobeck ș.a.(24), Chang(34) și Ypma(169) descriu sisteme cu memorii cu bule magnetice (bubble domain memory) și posibilitățile acestei tehnologii; Carnes ș.a.(30), Amelio (3) și Rege(139) descriu memorii utilizând dispozitive cu transfer de sarcină (charge coupled devices) și performanțele acestui tip de memorii. Alți cercetători descriu alte tipuri de memorii: Anacker (4)- memorii bazate pe efectul de superconductibilitate; Gillis ș.a.(85) - memorii holografice, Dell(50) și Scarrot(146) - memorii optice. De asemenea, sisteme de memorii cu utilizări speciale sînt descrise de Brewer ș.a. (27)- memorii BORAM, Spain ș.a.(154)- memorii DOT, Hughes ș.a.(95)- memorii BEAMOS.

Lucrări de sinteză și de definire a tendințelor de dezvoltare în acest domeniu sînt numeroase. Selectăm ca principale următoarele: Bogdan ș.a. (25), Cojanu ș.a.(42), Hoagland(90) și (91), Hodges(93) și (94), Laliotis(107), Mazda(122), Opran(132), Thomson ș.a.(157), Waas(161) și Williams(166). În bibliografia acestor lucrări pot fi găsite numeroase alte lucrări de interes.

Bazați pe caracteristicile tehnice superioare demonstrate în laborator pentru noi tipuri de memorii și presupunînd condiții de asimilare eficientă pentru producția de serie, este posibil să ne așteptăm la schimbări importante în următorii ani. În tabelul 1 sînt specificate caracteristicile de performanță, precum și costul unor tehnologii de memorii fie uzuale în prezent, fie de curînd descrise. Am dorit a da o imagine comparativă a performanțelor, ca și a costurilor. Astfel se poate observa că tipurile de dispozitive de memorii descrise acoperă aproximativ 8 ordine de mărime pe scala timpului de acces și aproximativ 4 ordine de mărime pe scala costului. Acest lucru este foarte semnificativ, dacă ținem seama de importanța care însoțește în mod normal o creștere de 10-20% în performanță sau o scădere de 10-20% în preț la sistemele curente contemporane.

NR.	TIP	VOLATIL	MECANIC	ACCES DATE	DIMENS.BITI	COST/BIT	TIME ACCES
1	TTL RAM	DA	NU	CUV.ALEATOR	$10^3-5.10^5$	5 ¢	60
2	MOS RAM	DA	NU	CUV.ALEATOR	$4.10^3-10^6$	1,25	300
3	RAM - MIEZURI	NU	NU	CUV.ALEATOR	$10^5-5.10^7$	0,7	500
4	MEMORII CCD	DA	NU	BLOC ALEATOR	$10^5-10^8$	0,1 config.n 10 config.1 2,5	
5	MEMORII BUBBLE	NU	NU	BLOC ALEATOR	$5.10^5-2.10^8$	0,03-config.n 0,5 - -0,05 config.1 1 s	
6	DISC FLE- XIBIL - TAMBUR	NU	DA	BLOC SERIAL	$5.10^5-5.10^6$	0,05	100 ms/
7	CASETA MAGN.	NU	DA	BLOC SERIAL	$10^6 - 10^7$	0,04	2
8	DISC CAPE- TE FIXE	NU	DA	BLOC SERIAL	$10^7 - 2.10^8$	0,08	8
9	DISC AMO- VIBIL	NU	DA	BLOC SERIAL	$5.10^7-5.10^9$	0,0025	50
10	BANDA MAGN.	NU	DA	BLOC SERIAL	$10^8 - 10^{10}$	0,0001	10

Tabelul 1. Ierarhie de dispozitive de memorii.

(4) Studiul comportării de acces a programelor și al comportării sistemelor de calcul.

Comportarea detaliată în exploatare a sistemelor de calcul este deseori foarte complexă. Astfel, unele decizii privind proiectarea hardware, software și de sistem trebuie deseori făcute pe baza unei cunoașteri insuficiente. O mai bună înțelegere a comportării de acces a programelor și a comportării sistemelor de calcul este esențială pentru dezvoltarea inteligentă și eficientă a sistemelor viitoare.

3. Parametrii principali ai unui sistem ierarhic de memorii.

Termenul "ierarhie de memorii" a fost utilizat pentru a descrie o varietate de configurații de memorii.

Corespunzător modului în care componentele sînt organizate, ierarhiile de memorii pot fi clasificate în două mari categorii:

./.

a) ierarhie centralizată. In această configurație o memorie centrală, principală, asigură unitatea centrală de prelucrare (UCP) cu informațiile pe care aceasta le necesită. Diferitele tipuri de dispozitive de memorii sînt conectate la această memorie principală prin canale și pot comunica unele cu altele numai prin memoria centrală.

b) ierarhie verticală. In această categorie intră configurațiile de memorii care sînt aranjate în ordine descrescătoare a vitezelor și crescătoare a capacităților (figura 1).

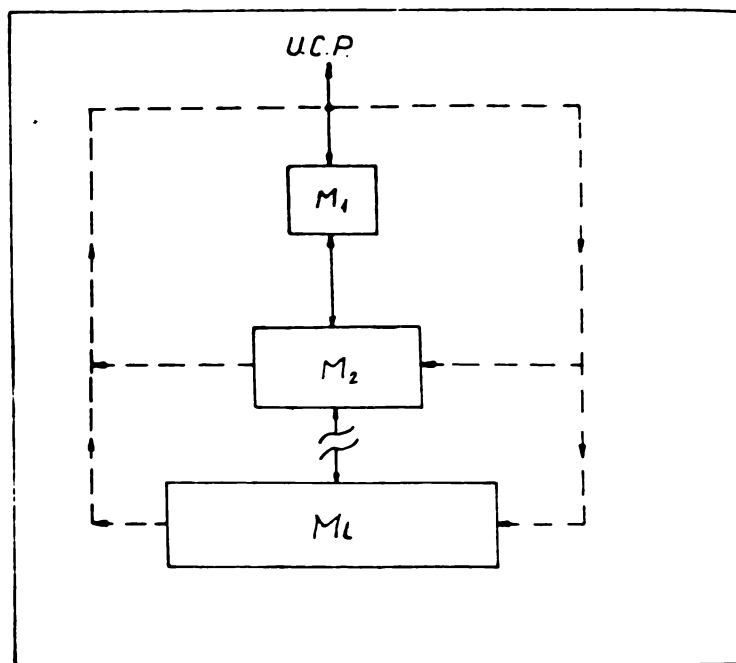


Fig.1. - Ierarhie verticală generalizată de memorii.

In această configurație memoriile pot comunica unele cu altele (chiar dacă nu sînt situate pe nivele învecinate) sau cu UCP, după cum este indicat în fig.1 prin linii întrerupte. In general însă, aceste canale transferă puține informații și poate fi presupus că memoriile pot comunica unele cu altele numai dacă sînt situate pe nivele alăturate. In același timp numai primul nivel al ierarhiei poate comunica cu UCP. Odată impuse aceste restricții ierarhia verticală de memorii va fi numită ierarhie lineară verticală de memorii (ILVM).

Inițial, toate informațiile rezidă în  $M_1$  și vor fi deplasate spre partea superioară a ierarhiei, pe măsura solicitărilor UCP. Deoarece  $M_1 < M_2 < \dots < M_l$ ,  $M_1$  va fi eventual plină;

cu scopul de a plasa o nouă "tranșă" de informații în acest nivel, este deci necesar a deplasa un anumit volum de informații din  $M_1$  în  $M_2$ , lucru ce ar putea conduce la o altă deplasare din  $M_2$  în  $M_3$  etc. Prin urmare informațiile circulă în timpul desfășurării calculelor vertical prin ierarhie, în ambele sensuri; informațiile care sînt utilizate la un anumit moment dat se găsesc în nivelele superioare ale ierarhiei.

Parametrii principali ai unei ILVM pot fi grupați în patru categorii: (1) tehnologia de bază, (2) configurația, (3) comportarea de acces a programului și (4) algoritmul.

### 3.1. Tehnologia de bază.

Parametrii tehnologiei de bază sînt:

$b_i$  costul/bit și  
 $t_i$  timp mediu de acces.

Fiecare nivel al ierarhiei este caracterizat de un cuplu de valori  $(b_i, t_i)$ . Acești parametri sînt, evident, dependenți de nivelul de dezvoltare al tehnologiilor de producere a dispozitivelor de memorii. Acest nivel permite realizarea, la un moment dat, a unui număr limitat de  $(b_i, t_i)$  alternative pe care le pune la dispoziția proiectantului de sistem (a se vedea tabelul 1).

Costul este o funcție descrescătoare de timpul de acces; curba reprezentată în fig.2 a fost construită pe baza datelor din tabelul 1.




Fig.2. - Costul/bit ca funcție de timpul de acces.

Timpul de acces este timpul consumat de un DI între momentul primirii unei adrese fizice de înregistrare a unei unități informaționale și momentul în care această unitate informațională devine disponibilă.

### 3.2. Configurația.

Parametrii ce intră în această categorie sînt următorii:

$l$  - numărul de nivele,

$c_i$  - capacitatea de memorizare,

$r_i$  - rata de transfer,

$p_i$  - dimensiunea paginii (numărul de octeți în pagină).

Proiectantul sistemului are o mare flexibilitate în organizarea dispozitivelor de memorii. Prin structurarea în serie și/sau paralel a componentelor unui anumit nivel al ILVM, este posibil să se realizeze o gamă largă de valori pentru capacitatea memoriei și rata maximă de transfer. Pe o bază mai largă, proiectantul trebuie să determine numărul nivelelor  $l$  în sistemul de memorii și  $p$  dimensiunea unei pagini (unitatea de informații transferată între două nivele vecine).

În privința alegerii dimensiunii unei pagini există trei strategii de bază:

(1) alegerea unei singure valori pentru dimensiunea paginii  $p$ , care este folosită peste tot în cadrul ierarhiei. Această abordare este folosită în cadrul majorității sistemelor cu gestiune automată cu mai multe nivele contemporane;

(2) posibilitatea de a alege un număr arbitrar de valori ale lui  $p$ . Această abordare este specifică sistemelor de memorii cu gestiune manuală;

(3) determinarea a  $l$  valori pentru  $p$ ; în cadrul transferului de informații între două nivele vecine ale ILVM fiind utilizată o dimensiune proprie de pagină.

### 3.3. Comportarea de acces a programului.

UCP, sub controlul programului, produce o serie secvențială de referiri la sistemul de memorii. Aceste referiri ale procesorului sînt sub formă unor referiri la adrese logice, ce servesc pentru a identifica în mod unic fiecare unitate individuală de informații memorată, indiferent de localizarea ei ( $A_1, A_2, \dots, A_n$ ). Secvența în timp a referirilor de adrese logice este denumită șirul de referiri. Un asemenea șir este notat astfel:

$$Z = z_1, z_2, \dots, z_\lambda$$

unde:

$z_t$  - numele adresei referită la momentul  $t$  și  $\lambda$  este lungimea șirului

În general, fiecare program, împreună cu datele lui de intrare, va genera un șir distinct de referiri. De remarcat că în această situație nu sîntem interesați de scopul programului sau limbajul utilizat la scrierea lui, ci doar de șirul lui de referiri.

Comportarea de acces a programului, observată din punctul de vedere al ierarhiei de memorii, este definită de secvența combinată de adrese de instrucții și de date emise de către program.

Deoarece deplasarea informațiilor în cadrul ILVI este realizată prin transferul de pagini, ca problemă de interes apare analiza acestui transfer de pagini. Acest lucru se poate realiza considerînd secvența în timp a referirilor la pagini logice; această secvență este numită șirul de referiri de pagină. Un șir de referiri de pagină, pentru valori date ale dimensiunilor  $p_i$  ale paginilor, este:

$$X(i) = x_1(i), x_2(i), \dots, x_{\lambda_i}(i)$$

unde:

$x_t(i)$  este numele paginii care conține  $z_t$ .

În cadrul ILVI, referirile sînt trecute spre un nivel mai inferior, numai dacă ele nu au putut fi satisfăcute de nivelele mai înalte. De aici rezultă că fiecare nivel va avea un șir diferit de referiri de pagină; toate aceste șiruri sînt derivabile algoritmic din același șir al referirilor.

Două concepte utilizate frecvent în studiul comportării unui program într-o ILVI sînt conceptele de spațiu al numelor și de proces.

### 3.3.1. Spațiul numelor.

Spațiul de nume (sau spațiul adreselor logice) reprezintă mulțimea numelor (a adreselor logice) disponibile unui procesor pentru a fi folosite ca identificatori de date.

Adresele logice sînt adresele folosite de programatori la scrierea unui program.



Un spațiu de adresare este caracterizat prin capacitate de adresare și structură. Capacitatea de adresare este dată de mulțimea adreselor disponibile, cu alte cuvinte de spațiul de adresare fizică.

Structura spațiului de adresare influențează modul de scriere al programelor.

Tipul cel mai frecvent de structură este cea lineară: într-un spațiu linear de nume numele permise sînt întregi  $0, 1, \dots, N$ . Capacitatea acestui tip de spațiu este determinată de numărul de biți utilizați pentru reprezentarea adreselor absolute.

Un alt tip comun de spațiu de nume este cel segmentat.

Un spațiu segmentat de nume este compus dintr-o mulțime de spații lineare distincte de nume. Fiecare spațiu linear de nume este utilizat pentru a adresa o mulțime ordonată de elemente de informație, ce au fost declarate ca formînd un segment. Un spațiu segmentat de nume este deseori descris ca un spațiu bidimensional de nume, deoarece pentru a adresa un element de informație este necesar să se specifice două nume (numele segmentului și numele elementului în segment). Diferite segmente pot avea dimensiuni diferite.

Segmentarea realizează adresarea relativă în spațiul de nume, prin diviziunea spațiului de nume în locații contigue (segmente) și considerarea adreselor din interiorul unui segment ca fiind adrese relative la începutul acestuia.

Avantajele aduse de segmentare decurg din faptul că segmentul reprezintă o notație comodă de nivel înalt pentru crearea unei structurări semnificante a informațiilor utilizate de un program (138). Astfel, între avantajele utilizării acestei structuri se numără:

(1) segmentele formează o unitate foarte comodă pentru realizarea diviziunii informațiilor între programe.

Proceduri sau rutine reutilizabile (ce nu pot fi modificate) pot fi adresate simultan de cîțiva utilizatori. Din cauza segmentării lucrărilor independente este posibil să se creeze și să se folosească informații dintr-o bază comună; prin limitarea privilegiilor de acces un segment poate fi protejat de utilizatori neautorizați.

(2) se creează posibilitatea modularizării. Secțiuni ale unor lucrări mari pot fi identificate, compilate și executate independent. Uneori o lucrare mare poate fi constituită din rutine scrise independent. Astfel de module de programe sînt legate în momentul execuției.

(3) utilizarea unui spațiu segmentat de nume creează facilități în manipularea masivelor de date. Astfel, pentru fiecare mulțime de elemente de informație, a cărei dimensiune variază dinamic, se poate folosi un segment distinct.

Spațiul segmentat de nume poate fi clasificat corespunzător caracteristicilor spațiului prevăzut pentru nume de segmente, adică pentru primul termen al perechii ordonate (nume de segment, numele elementului în cadrul segmentului). Astfel, pentru nume de segmente se pot folosi spații de nume linear sau simbolic. În consecință se vor deosebi spațiul segmentat linear de nume și spațiul segmentat simbolic de nume.

Diferența principală între aceste două tipuri de spații segmentate de nume este că în cadrul spațiului segmentat simbolic segmentele nu sînt ordonate în nici o privință, dat fiind că utilizatorii nu sînt înzestrați cu nici un mijloc de manipulare a unui nume de segment pentru a produce alt nume. Lipsa ordonării înseamnă că nu există o contiguitate a numelor (adică nu există nici o relație între ultima adresă a unui segment  $N$  și prima adresă a segmentului  $N + 1$ ), ce să provoace genul de probleme care sînt prezente în cadrul procedurilor de alocare a memoriei și relocare a adreselor (138). În consecință, un spațiu segmentat simbolic de nume implică proceduri mai simple de administrare decît spațiul segmentat linear.

Un avantaj posibil al utilizării unui spațiu segmentat linear de nume este faptul că el permite indexarea pentru numele de segmente. Aceasta deoarece în cadrul segmentării lineare, la trecerea dintr-un segment în altul, adresele sînt în continuare. Ultima adresă a segmentului  $N$  este urmată de prima adresă a segmentului ( $N + 1$ ); deci este posibilă modificarea prin indexare a unei adrese din segmentul  $N$  pentru obținerea unei adrese din segmentul ( $N + 1$ ).

Exemple de sisteme ce utilizează spații segmentate simbolic de nume sînt: Multics - GE 645 (48; 133), iar sisteme ce utilizează spații segmentate linear de nume sînt: IBM - 360/67 (83), IBM - 370 (98), RCA-SPECTRA 70/46 (131).

Intre numele din spațiul numelor și locațiile din memoria fizică nu există nici o relație apriorică; această corespondență se stabilește în cadrul mecanismului de translație a adreselor (7) (fig.3.).

În cadrul unor sisteme de calcul ce utilizează un spațiu segmentat de nume, segmentele reprezintă și unitatea de alocare fizică a memoriei. Așa este cazul sistemului Burroughs (117).

Mai frecvent însă, pentru a simplifica transpunerea segmentelor de dimensiune arbitrară într-o memorie de dimensiune fixă, cît și pentru utilizarea mai eficientă a memoriei interne, segmentele și memoria internă sînt împărțite în blocuri egale ca dimensiune, numite pagini. Pagina, transparentă pentru programator, este unitatea standard de memorare și transmisie a informațiilor. Spațiul memoriei interne este împărțit în cadre de pagină. Segmentele de lucrare, așa cum sînt primite de la utilizatori, sînt încărcate în nivelul 1 al ierarhiei de memorii  $M_1$ ; în timpul executării programului, pagini individuale ale unui segment sînt transferate spre partea superioară a ILVM, ajungînd în cadre de pagină ale memoriei principale  $M_1$ . Această metodă este numită paginare și se referă deci la organizarea și alocarea spațiului fizic de memorare.

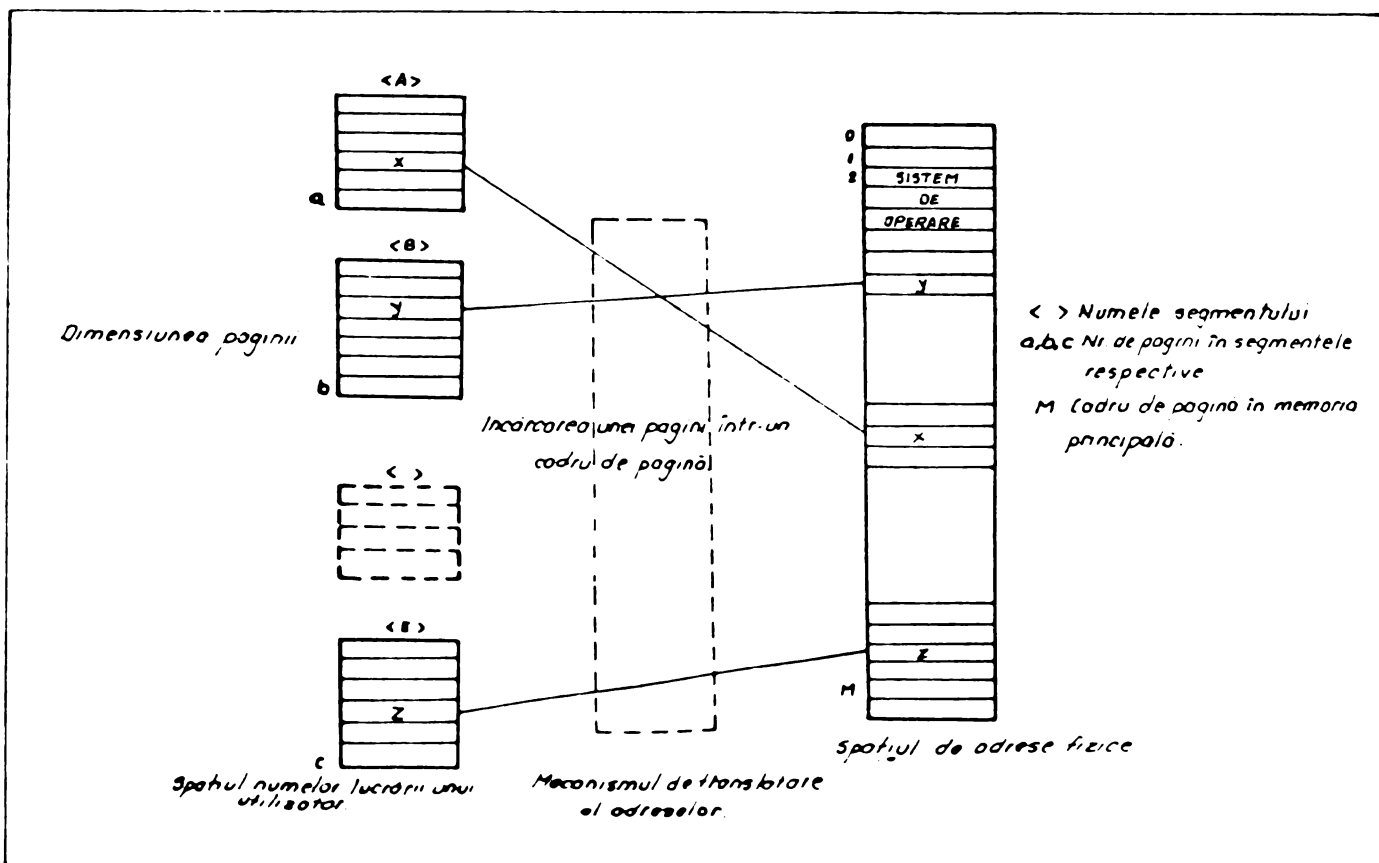


Fig.3 Reprezentarea spațiului numelor și al adreselor fizice

Metoda paginării se poate referi și numai la memoria internă; în acest caz se realizează o administrare mai simplă a memoriei interne, iar alocarea zonelor de memorie pentru programe se face prin alte metode (25). În cazul sistemelor cu memorii virtuale, paginarea se referă la ansamblul de dispozitive de memorii disponibile, operînd în cadrul ierarhiei.

Traducerea adreselor din spațiul numelor în adrese fizice este denumită mecanismul de translatare a adreselor.

În continuare, vom exemplifica acest mecanism de translatare a adreselor în cadrul schemei de segmentare cu paginare utilizate în sistemul Multics (48). Pentru adresarea memoriei trebuie cunoscut numărul segmentului și adresa (relativă) din cadrul segmentului; această formă a adresei se numește adresă generalizată. Pentru fiecare program de utilizator din sistem există un tabel descriptor de segmente (TDS); acest tabel conține câte un cuvînt denumit cuvînt descriptor de segment (CDS) pentru fiecare segment cunoscut programului respectiv. Pentru un program în execuție, adresa de început a tabelului descriptor de segmente (TDS) este conținută în registrul de bază pentru un segment descriptor (RBD). Adresa din cuvîntul descriptor de segment (CDS) reprezintă adresa de început a unui tabel de pagini, ce conține cuvinte descriptor de pagini (CDP), ce compun acel segment. Descriptorul unei pagini conține adresa fizică de început a paginii respective și informații cu privire la pagină (existența sau absența în memoria internă, iar în cazul existenței, dacă a fost sau nu modificată de la aducerea în memoria internă etc.).

O asemenea schemă este arătată în fig.4.




Fig.4. Schemă de translatare a adreselor cu două nivele

Aceeași schemă de bază de translatore a adreselor indicată în fig.4 se utilizează și în cadrul sistemelor 360/67 și 370 (138,96).

Un mecanism de paginare mai complicat este întâlnit în cadrul configurațiilor DEC System 20 (106), permițând sistemului de operare să realizeze o administrare mai eficientă a programelor pe baza paginării la cerere (vezi secțiunea 3.4 a acestui capitol) și o înaltă diviziune a datelor și programelor. Acest mecanism este realizat printr-o combinație de hardware și microcod, numită facilitare de paginare. Această facilitare utilizează urmărirea adreselor de pagină pe mai multe nivele.

Un spațiu de adrese de 256 Kcuv. (1 cuv. are 36 biți) formează o secțiune, care este identificată printr-un indicator de secțiune. Un indicator de secțiune indică un tabel de pagini, care la rândul lui conține indicatori reprezentând fiecare pagină a acelei secțiuni. Indicatorul de secțiune poate fi de format imediat, cu diviziune sau indirect; în fiecare caz el indică adresa din memoria principală a unei pagini, care conține un tabel de pagini. Un tabel de pagini este o pagină ce conține indicatori de pagină pentru o secțiune. Într-o secțiune există 512 pagini, iar fiecare indicator este un cuvânt. Având în vedere că dimensiunea unei pagini este de 512 cuvinte, rezultă că un tabel de pagini este o pagină completă.

Un indicator imediat conține adresa fizică a paginii corespunzătoare. Acest tip de indicator este denumit de asemenea propriu, deoarece pagina este proprie doar tabelului de pagini ce conține acest indicator.

Un indicator cu diviziune conține un index ce indică locul tabelului de pagini speciale/ cu diviziune (SPT). Intrarea corespunzătoare din SPT conține adresa fizică pentru pagină. Intrarea SPT este găsită la adresa de memorie fizică obținută prin sumarea conținutului registrului de bază SPT și a indexului SPT din indicatorul cu diviziune. Acest indicator este numit cu diviziune, deoarece mai multe tabele de pagini pot conține asemenea indicatori, care să se refere la aceeași pagină fizică. Indiferent de numărul de tabele de pagini ce conțin un asemenea indicator cu diviziune, adresa fizică este înregistrată o singură dată în SPT.

De aceea monitorul poate deplasa pagina, avînd de actualizat numai o singură adresă. Un indicator indirect identifică un alt tabel de pagini și un indicator în cadrul aceluși tabel de pagini. El determină extragerea și interpretarea noului indicator.

Indicatorul indirect este folosit pentru a face o pagină a unui spațiu de adrese echivalentă unei pagini a altui spațiu de adrese. Indicatorul indirect identifică tabele obiecte de pagini, folosind un index SPT. Adresa fizică a tabelului de pagini este găsită la intrarea corespunzătoare din SPT la fel ca în cazul indicatorului cu diviziune. Acesta este realizat astfel încît adresa fizică a unui tabel de pagini să poată fi conținută într-un singur loc și să nu necesite a fi duplicată în indicatorii de pagină. Indată ce tabelul obiject de pagină a fost găsit, cîmpul cu numărul paginii din cadrul indicatorului indirect este utilizat ca index pentru a selecta un nou cuvînt indicator din tabelul de pagini. Acest nou indicator poate fi de oricare tip din cele trei tipuri, facilitatea de paginare putînd interpreta lanțuri de indicatori indirecti cu o lungime oarecare.

Un tabel cu pagini speciale/cu diviziune SPT conține adrese fizice pentru pagini ce sînt folosite de mai multe tabele de pagini sau care sînt folosite într-un mod special, de exemplu tabele de pagini. Un registru conține adresa de bază a SPT. Indexul SPT găsit în indicatori este adunat la adresa de bază a SPT pentru a forma adresa de memorie fizică a intrării corespunzătoare. Intrarea SPT conține o adresă fizică.

Fluxul de interpretare al indicatorilor este descris în (106).

Prezența sau absența unei anumite pagini în memoria principală este precizată de starea cîmpului (poziționat 1 sau 0) de prezență a paginii în memoria principală. Un asemenea cîmp este asociat fiecărei intrări a tabelului de pagini.

În cazul în care procesorul încearcă să adreseze o pagină al cărui cîmp de prezență în memorie este poziționat 0 (indicînd deci lipsa ei), se generează prin hardware o între-

rupere automată a execuției programului în curs de desfășurare, iar procesorul inițiază acțiunea de aducere a paginii lipsă în memoria principală dintr-un nivel inferior al ILVM. O asemenea situație este numită defect de pagină (page-fault). După ce pagina cerută a fost plasată în memoria principală fiind utilizabilă, intrarea corespunzătoare în tabelul de pagini este actualizată; câmpul de adresă va conține adresa memoriei principale unde începe cadrul de pagină alocat, iar câmpul de prezență în memorie este poziționat 1. În acest moment este reluată execuția întreruptă a programului care a necesitat aducerea acestei pagini. Mai târziu, când pagina va fi scoasă din memoria principală, câmpul de prezență al acestei pagini va fi din nou poziționat 0.

Translatarea adreselor logice în adrese fizice este o operație ce implică deci mai multe consultări de tabele din memorie, ceea ce necesită un anumit timp. Pentru a scurta acest timp de consultare se pot utiliza registre sau memorii imediate rapide, pentru memorarea tabelor de pagini. Această soluție este convenabilă numai pentru calculatoarele de capacități mici, respectiv cu un număr mic de pagini fizice. O soluție eficientă în cazul calculatoarelor de capacități medii și mari este utilizarea unor memorii (registre) asociative (adresabile prin conținut), în care se memorează atât adresa virtuală, cât și cea reală a unor pagini de program selectate după anumite reguli (vezi secțiunea 3.4 - algoritm - a acestui capitol). În alocarea registrelor asociative se pot adopta diferite soluții. Cele alese pentru sistemele Multics și IBM 360-67 sînt descrise în (134) și respectiv (83).

În cazul utilizării unor memorii asociative, la translatarea unei adrese virtuale se cercetează mai întîi aceste registre asociative. În cazul în care adresa virtuală căutată este memorată în unul din aceste registre, din același registru se poate obține și adresa fizică a începutului cadrului de pagină corespunzător. În cazul că în registrele asociative nu se găsește adresa virtuală căutată, va fi necesară consultarea tabelor din memorie. Scurtarea timpilor de căutare se realizează pe seama timpului de acces mai mic al registrelor asociative, com-

parativ cu cel al memoriei principale.

Utilizarea registrelor asociative poate fi realizată pentru translatarea adreselor unui spațiu de nume, atât unidimensional, cât și bidimensional. În primul caz se utilizează memorii asociative cu o singură trecere (cazul sistemului IBM 360-67); în cel de-al doilea caz este necesară utilizarea unor memorii asociative cu două treceri: (sistemul Multics): la prima trecere se urmărește identificarea numelui segmentului, la cea de-a doua numărul paginii în cadrul segmentului (133).

O tratare mai largă a conceptului de segmentare și a procedurii de paginare poate fi găsită în (133) și (25).

Trebuie remarcat că, din punct de vedere teoretic, orice sistem ar putea implementa o ILVM în software. Ceea ce ar trebui făcut este aplicarea unor "capcane" pentru adrese și crearea unor tabele de referință și a unui program de evidență a corespondențelor adreselor. Într-un sens mai riguros, se precizează că un sistem conține o ILVM când aspecte importante funcționale ale unui asemenea sistem au fost implementate prin hardware. Astfel, adresarea virtuală modifică structurile de adresare reală prin:

- permiterea canalelor I/E de a folosi adresarea indirectă;
- acceptarea de către UCP a adreselor de date ce depășesc capacitatea lui de memorie reală;
- asigurând o schemă de translatare a adreselor din virtuală în reală și invers.

În cazul IBM - System 370 aceste lucruri se realizează prin facilitățile:

- channel indirect data addressing;
- extended core mode;
- dynamic address translation.

În cazul acestui sistem, memoria paginată externă (ajungând la o capacitate de 16 Mo) utilizează segmente de 16 Ko sau 1 Mo și pagini de 2 Ko sau 4 Ko (1 Ko = 1024 octeți). Diviziunile folosite sînt funcție de alegerea sistemului de operare. Partea de translatare dinamică a adreselor este implementată hardware, iar evidența corespondențelor paginilor este sub su-



pravegherea sistemului de operare. Procesul de translatare a adreselor și de evidență a corespondențelor paginilor sînt transparente pentru utilizator, ce operează simplu cu o structură logică obișnuită de adrese.

O realizare deosebită în domeniu este facilitatea de extensie a spațiului de adrese virtuale în sistemul DEC 10 (106). Această facilitate de adresare extinsă mărește spațiul de adrese virtuale de utilizator la 1 bilion de cuvinte, permițînd programelor de utilizator să adreseze pînă la 4096 secțiuni, fiecare a 256 Kcuvinte. Fiecare instrucție specifică o adresă de 30 biți, implicit, sau explicit. Programatorul poate utiliza secțiunile ca entități logice separate sau ca un spațiu unic de adresare contiguu. Masivele și șirurile de date pot fi arbitrar de lungi și pot traversa granițele secțiunilor. Însă șirul de instrucții trebuie să transfere controlul în mod explicit între secțiuni și nu poate trece granițele de secțiuni. Cu scopul de a specifica adrese de 30 biți, indexarea și adresarea indirectă a calculatorului au fost modificate (106) .

### 3.3.2. Proces.

Procesul este noțiunea prin care se definește execuția unui program de către un procesor într-un mediu cu memorie virtuală.

O definiție echivalentă a procesului este aceea conform căreia un proces este o secvență ordonată de referiri la informațiile înmagazinate în spațiul numelor, sub controlul unui flux de instrucții.

Un proces are patru stări de existență în timp real:

(1) în desfășurare, înțelegînd prin acest lucru că el obține posibilitatea de utilizare a procesorului;

(2) gata de desfășurare; procesul cere, dar nu obține utilizarea procesorului; cu alte cuvinte procesul este întrerupt din cauză că procesorul este utilizat de un alt proces;

(3) în așteptarea unei pagini; procesul este temporar întrerupt din cauză că lipsește o pagină din  $M_1$ . Execuția este reluată imediat ce pagina lipsă a fost plasată în  $M_1$  și procesorul este disponibil;

(4) blocat; procesul nu cere utilizarea procesorului, din cauză că așteaptă producerea unor evenimente externe (așteptate), astfel ca un mesaj sau un semnal de la alt proces, de la un aparat sau de la un utilizator aflat la o consolă.

Figura 5 ilustrează tranzițiile posibile între aceste stări.

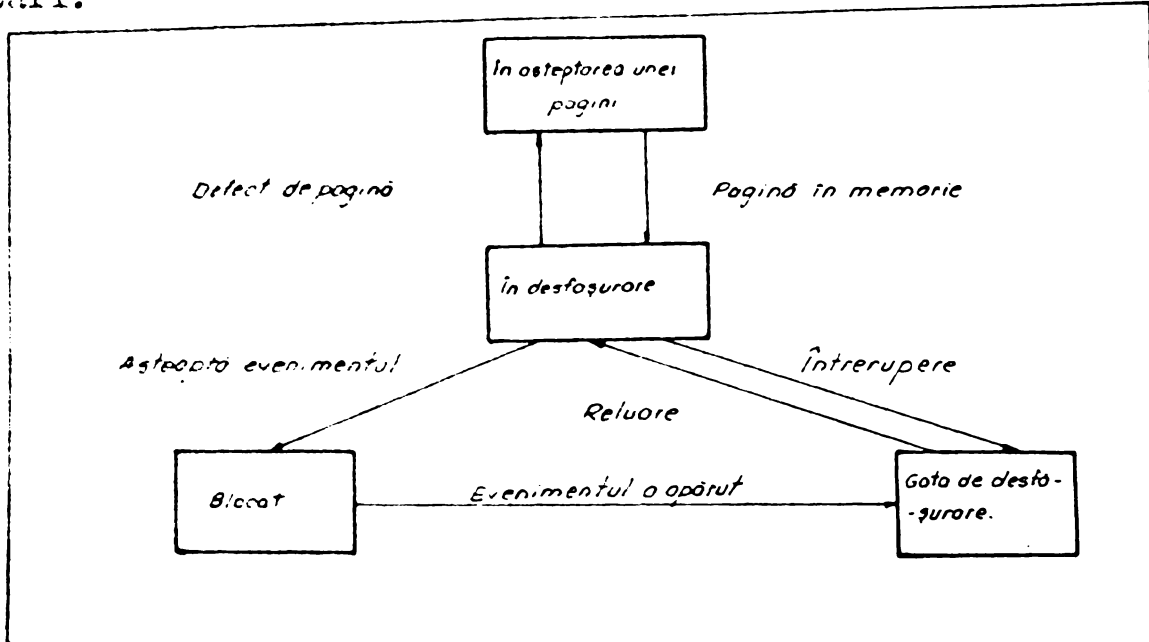


Fig.5. Stări ale unui proces.

Tranziția de la starea "în desfășurare" la cea "gata de desfășurare" apare ca urmare a unei întreruperi decise de sistemul de operare cu scopul de a asigna procesorul unei alte utilizări, de exemplu execuției unui alt proces.

Tranziția de la starea "gata de desfășurare" la cea de "în desfășurare" - specificată ca reluare - apare ca urmare a deciziei sistemului de operare de a aloca din nou procesorul acestui proces.

Tranziția arătată în fig.5 de la starea "în așteptare a unei pagini" la cea de "în desfășurare" are corespondent în realitate situației existenței unui procesor asignat permanent acestui proces, ce ar fi imediat disponibil continuării execuției, în momentul când procesul a obținut pagina găsită lipsă. Dacă însă timpul de așteptare pentru a obține pagina lipsă este mai mare decât timpul necesar comutării procesorului altui proces, nu este economic a asigna procesorul unui singur proces și în acest caz procesul se întoarce în starea de "în

desfășurare" prin starea de "gata de desfășurare" .

Vorbind despre procese, facem o distincție între timpul virtual și timpul real. Timpul virtual este timpul observat de către un proces, dacă nu ar fi niciodată întrerupt, deci timpul total acumulat în starea de desfășurare. Timpul virtual, numit de asemenea timp de execuție sau timp de proces, este măsurat în unități de timp virtual, de obicei cicluri ale memoriei  $M_1$ .

O unitate de timp virtual este intervalul între două referiri succesive la informațiile ce constituie un proces. Vom considera timpul virtual ca fiind continuu, deși în realitate este discontinuu, dar intervalul între două valori consecutive este foarte mic.

Timpul real este timpul virtual, la care se insertează corespunzător întârzierile ce se referă la stările de "în așteptarea paginii", "blocat" și "gata de desfășurare" .


Deoarece un proces este o secvență ordonată de referiri la informații el este deseori numit un proces secvențial. Într-un sistem de calcul multiprocesor, pot fi executate simultan mai multe procese; avem de-a face cu procese secvențial-paralele.

În interesul generalității programării și de asemenea cu scopul de a asigura o protecție totală a fiecărui utilizator, sistemele moderne cu memorii virtuale oferă facilitatea unui calculator virtual (99, 100). Un calculator virtual este un echivalent simulat al unui calculator real și constă din UCP virtuală, memorie virtuală și dispozitive I/E virtuale. Sistemul de operare are sarcina de a simula UCP, memoria și dispozitivele I/E.

În sistemul Multics, mecanismul de control al traficului (133) tratează asignarea procesorilor reali la procesori virtuali și comunicarea între procesorii virtuali.

În cadrul IBM - System 370 Virtual Machine Facility - VM/370 (99) permite utilizatorilor să dezvolte calculatoare virtuale. VM/370 alocă resursele reale ale sistemului utilizatorilor prin modul de diviziune al calculatorului. Utilizatorii primesc frecvent intervale de timp de UCP și își împart memoria reală a sistemului prin utilizarea paginării la cerere (vezi secțiunea 3.4. a acestui capitol). Componenta principală a VM/370 - Control Program - administrează resursele System/370, inclusiv timpul UCP,

./.



pentru a crea și controla multiple calculatoare virtuale simultane, ce pot rula sub diferite sisteme de operare.

Deși programul de utilizator este în mod tradițional gândit ca un ansamblu de elemente componente - module de instrucții de program, masive de date, proceduri și subrutine - programul nu poate rula izolat într-un calculator. Programul necesită resurse software, precum tratarea întreruperilor, a cererilor de serviri I/O etc. În trecut acest software nu era considerat ca fiind o parte a programului, în mod logic însă aceste două părți interacționează și formează un ansamblu unitar complet. Un asemenea ansamblu poate fi executat într-un calculator virtual, care asigură utilizatorului toate resursele sistemului de care acesta are nevoie (100). Fiecărui utilizator îi apare să aibă acces la disponibilitățile funcționale complete ale unui asemenea sistem.

#### 3.4. Algoritm.

Gestiunea unei ierarhii de memorii are rolul de a decide cum trebuie organizată informația în cadrul ierarhiei între nivelele acesteia și în cadrul fiecărui nivel și a decide când să se transfere informația între nivelele ierarhiei. Algoritmii utilizați în transferul de pagini între nivelele ierarhiei operează în două sfere.

(1) aducere (plasare): localizează pagina cerută într-un nivel al ierarhiei și o încarcă în memoria principală  $M_1$ , poziționează 1 bitul de prezență a respectivei pagini în intrarea corespunzătoare a tabelului de pagini;

(2) înlocuire (replasare): înlocuiește o pagină din  $M_1$ , poziționează 0 bitul de prezență a intrării respective a tabelului de pagini.

Regula utilizată pentru a decide ce pagină trebuie înlocuită este numită algoritm de înlocuire.

Algoritmii de gestiune pot încărca pagini în  $M_1$  înainte de a fi necesitate (pre-paginare), la momentul în care sînt necesitate (paginare la cerere) sau chiar mai tîrziu.

Multe strategii utilizează paginarea la cerere, adică nu este întreprinsă nici o acțiune de aducere a unei pagini în memoria principală pînă ce un proces nu face o referire la

ea. Paginarea la cerere este de obicei preferată pre-paginării, căci costul implementării este mai mic și deoarece pre-paginarea nu îmbunătățește considerabil performanța.

După cum s-a arătat mai sus, în mod obișnuit nu există informații anterioare relative la problemele de alocare a resurselor. Singurul argument important favorizând pre-paginarea este posibilitatea deplasării unor blocuri mari continue de pagini din nivelele inferioare ale ierarhiei, astfel că timpul de acces cumulat este mai mic într-o rulare lungă.

Problema majoră în cadrul gestiunii unei ILVM nu este a decide care pagină să fie încărcată, ci a decide ce pagină să fie înlocuită. Un algoritm de gestiune al ILVM ar trebui să încerce să mențină în  $M_1$  paginile care sînt cele mai probabile de a fi utilizate. Astfel, cea mai bună alegere pentru înlocuire o oferă pagina cu cea mai mică probabilitate de a fi utilizată din nou, imediat.

În continuare vom prezenta comparativ strategiile curen-te de înlocuire.

Dacă o pagină a fost modificată de la aducerea ei în  $M_1$  înlocuirea ei implică transferarea ei într-un nivel  $M_i$ ; o pagină nemodificată este pur și simplu ștearsă, căci presupunem că există o copie a ei într-un nivel  $M_i$ .

Alocarea de pagini în nivelul  $M_1$  al unei ILVM în cadrul unui sistem ce permite multiprogramarea (cum sînt majoritatea sistemelor moderne contemporane) poate fi tratată pe baza unei diviziuni fixe sau variabile:

(1) diviziunea fixă; înainte de a fi rulat, unui program îi este garantată o diviziune fixă a memoriei  $M_1$  pentru uzul privat;

(2) diviziunea variabilă; programelor le este permisă libera concurență pentru spațiul de memorie. În aceste condiții, necesitățile unui program, apărute în cursul desfășurării lui, pentru un spațiu de memorie mai mare sau mai mic, conduc la alocarea acestui program a unei cote părți (diviziune) din memorie, mai mare sau, corespunzător, mai mică.

Intr-un context de elemente identice, se poate arăta că

strategiile cu diviziunea variabilă a memoriei conduc la probabilități de lipsă a unor pagini (vezi secțiunea 4.1.) mai mici decât cele în cazul strategiilor cu diviziune fixă.

Algoritmii de înlocuire (care pot fi utilizați cu strategii de bază atât cu diviziunea fixă, cât și cu diviziunea variabilă a memoriei) se împart în următoarele trei clase, ordonate în termenii creșterii costurilor, aferente logicii cerute pentru implementare.

(1) algoritmi statici - înlocuirea este făcută conform unei reguli predeterminate; ei nu folosesc nici o informație privind utilizarea paginilor; aceste reguli sînt simplu de implementat;

(2) algoritmi de utilizare ce folosesc informații privind utilizarea paginilor, în general măsurînd intervalele de timp de la ultima referire la fiecare pagină;

(3) algoritmi de cerere ce încearcă să predetermine, pe baza mostrelor de referiri curente, grupul de pagini cel mai probabil de a fi folosit imediat.

Unui program îi este acordat mai mult sau mai puțin spațiu corespunzător cererii lui pentru spațiu.

Se poate arăta (130) că în situații identice, algoritmi statici conduc la probabilitățile de lipsă a unei pagini cele mai ridicate, și că algoritmi de cerere la probabilitățile cele mai mici.

Există doi algoritmi statici de interes:

(1) aleator (RAND). Ori de cîte ori este necesită o pagină nouă în memorie, o pagină este selectată aleator pentru a fi înlocuită.

Implementarea este simplă, necesitînd numai un generator de numere aleatoare.

(2) primul intrat, primul ieșit (FIFO). Ori de cîte ori este necesită o pagină nouă în memorie, este solicitată pentru a fi înlocuită pagina care a fost adusă în memorie cel mai puțin recent (adică de intervalul cel mai lung de timp). În timp ce algoritmul RAND implică un generator de numere aleatoare, FIFO cere un contor și implementarea este chiar mai simplă, după cum urmează.

Paginile nivelului  $M_1$  sînt considerate un grup ciclic; presupunem c  cele  $N$  pagini ale lui  $M_1$  sînt numerotate  $0, 1, \dots, N-1$   i un punctator  $k$  arat  c  pagina  $k$  a fost cea mai puţin recent adus   n  $M_1$ . C nd este cerut  o nou  pagin ,  $(k+1) \bmod N \rightarrow k'$   i pagina  $k$  este  nlocuit .

Principalul argument pentru eventuala utilizare a acestor doi algoritmi statici este simplitatea lor de implementare,  ns  rezultate experimentale (18,19,159) arat  c  algoritmi de utilizare,  n ciuda unor costuri mai ridicate, dep şesc considerabil  n performan  algoritmi statici.

Exist  urm torii algoritmi de utilizare de interes:

(1) cel mai puţin recent utilizat (least recently used-LRU).

Ori de c te ori este necesar  o nou  pagin   n memorie, este  nlocuit  pagina nereferit  de cel mai lung interval de timp.

Implementarea este posibil   n felul urm tor:

Fiecare intrare  n tabelul de adrese al paginilor conţine un bit de utilizare, care este poziţionat 1 la fiecare nou  referire a paginii respective. La intervalele periodice, toate intr rile tabelului de pagini s nt cercetate, biţii de utilizare poziţionaţi 0  i  nregistr rile de utilizare actualizate. La apariţia unui defect de pagin , este solicitat  pentru  nlocuire pagina a c rei  nregistrare de utilizare specific  intervalul cel mai lung de timp de la ultima referire;

(2) cel mai puţin frecvent utilizat (least frequently used-LFU).

Intr-o manier  asem n toare celei descrise  n cadrul algoritmului LRU, paginile s nt organizate conform frecvenţei referirii  i algoritmul selecteaz  pentru  nlocuire pagina care a fost referit  de num rul cel mai mic de ori;

(3) primul adus, nefolosit, primul  nlocuit (first in not used, first out - FINUFO) (133).

Implementarea este aproximativ identic  ca  n cazul algoritmului FIFO, cu deosebire c   n cadrul acestui algoritm se folosesc  i biţii de utilizare din tabelul de pagini.

Fie  $k$  punctatorul ce cicleaz  pe cele  $N$  pagini ale memoriei  $M_1$ . Ori de c te ori apare un defect de pagin ,  $k$  este incrementat p n  ce este g sit  o pagin  al c rei bit de utilizare

este poziționat 0; această pagină este selectată pentru înlocuire. Când  $k$  traversează o pagină al cărei bit de utilizare este poziționat 1, acest bit este comutat.

Acest algoritm ce combină simplitatea lui FIFO cu caracterul mai sofisticat al LRU a fost propus pentru sistemul Multics.

#### (4) detectare de cicluri ATLAS

Calculatorul Ferranti-Atlas (105) are o strategie de paginare ce încearcă să detecteze comportarea ciclică în mostrele de referire a paginilor.

Acest lucru se realizează prin supravegherea lungimii de inactivitate (perioade de timp fără referiri) pentru fiecare pagină; pe baza acestor valori sînt presupuse valorile următoarei perioade de inactivitate. Înlocuirea se îndreaptă spre acele pagini care au o valoare mare presupusă de inactivitate; obiectivul principal al acestui algoritm a fost să detecteze cicluri în programe cu scopul de a încerca să memoreze blocurile pe care acesta le conține.

Performanța a fost satisfăcătoare pentru programe ce manifestă o comportare de acces ciclică și nesatisfăcătoare pentru programe ce manifestă un caracter aperiodic în mostrele de referiri la memorie din cauză că algoritmul încerca să detecteze cicluri acolo unde nu existau.

Implementarea este costisitoare;

(5) OPT (121). Acest algoritm de înlocuire se poate dovedi optim în aceea că produce numărul minim de referiri la pagini, care nu se găsesc în memoria  $M_1$ . Cu scopul de a aplica acest algoritm, trebuie cunoscute mostrele exacte de referire ale programelor ce alcătuiesc sarcina sistemului.

Intr-o trecere a șirului de referiri de pagină, algoritmul înregistrează dinamic acele pagini care vor fi referite din nou mai tîrziu. În acest mod se poate obține o ordine determinată aprioric de înlocuire a paginilor.

Algoritmul nu este practic, căci presupune cunoașterea în avans a mostrelor de referire, însă este foarte util ca termen de comparație în analiza altor algoritmi de înlocuire.



Algoritmii de cerere sînt bazați pe necesitățile dinamice de memorie ale programelor, ce alcătuiesc sarcina sistemului.

Două categorii de algoritmi justifică cercetarea:

(1) strategia de grup de lucru (52,57).

Grupul de lucru al unui program (vezi cap.4 secțiunea 1.2 pentru o descriere mai completă) este definit ca numărul distinct de pagini referite de către program în decursul unui anumit interval de timp; acest interval de timp este cunoscut ca reprezentînd parametrul grupului de lucru.

Intr-un mediu multiprogramat numai acele programe sînt eligibile de a putea fi rulate, a căror grup de lucru nu depășește spațiul propriu disponibil în memoria  $M_1$ ; acest lucru garantează că suma grupurilor de lucru ale tuturor programelor active nu depășește dimensiunea  $M_1$ . Odată ce programul devine activ, el se poate dezvolta după necesități, în concordanță cu fluctuațiile în dimensiunea grupului lui de lucru. In caz de necesitate, el poate înlocui pagini din alte programe, conform unui alt algoritm.

Această strategie este atît un algoritm de planificare, cît și unul de înlocuire.

Fiecare pagină aparținînd grupului de lucru la un moment dat, a unui program oarecare în rulare, trebuie să fie menținută în memoria  $M_1$ . Paginile ce nu fac parte din grupul de lucru sînt obiect de înlocuire la apariția necesității de spațiu.

Prin variația parametrului grupului de lucru astfel ca să conțină mereu un număr fix de pagini, strategia de grup de lucru poate fi utilizată pentru a simula algoritmul LRU (56).

Ca o deficiență intrinsecă asociată acestui algoritm, remarcăm dificultatea de a măsura dinamic parametrul de grup de lucru, cu scopul de a estima dimensiunea grupului de lucru;

(2) algoritm de tip Round-Robin modificat. In cadrul acestui algoritm fiecare program este favorizat în cadrul unui anumit interval de timp. In timpul intervalului lui de favorizare, un program se dezvoltă înlocuind pagini ale altor programe. Pagina aleasă pentru înlocuire este selectată pe baza altui algoritm.

O deficiență a acestui algoritm constă în dificultatea de a selecta un interval de timp corespunzător.

Aprecieri generale.

Una din lucrările clasice privind analiza algoritmilor de înlocuire este cea a lui Belady (18). Iată unele din concluziile lucrării:

- FIFO nu este semnificativ mai bun decât RAND; în câteva cazuri, chiar mai slab;

- LRU și FINUFO sînt considerabil mai buni decât algoritmi statici. Precizia cu care este înregistrată istoria trecută a procedurii de paginare nu pare să fie deosebit de importantă.

În ciuda complexității, algoritmul de detectare a ciclurilor ATLAS a fost apreciat ca producînd rezultate slabe; în unele cazuri performanța obținută cu acest algoritm a fost chiar mai rea decât utilizînd FIFO sau RAND (104). Motivul pentru această comportare neașteptată, pare să fie în variația largă a dimensiunii ciclurilor programelor.

Denning (56) compară FIFO, LRU, FINUFO, RANDOM și strategia de grup de lucru propusă de el, rezultatele lui fiind în concordanță cu Belady (18).

Apare desigur întrebarea: "Cît de importantă este funcția algoritmului de înlocuire în performanța globală a unei ILVM?" Multe cercetări independente (84,89,123) indică că efectul algoritmului de înlocuire este de o importanță secundară.

Din rezultatele acestor lucrări menționate poate fi desprinsă următoarea concluzie. Dacă nu sînt admise costuri mari pentru implementarea algoritmului de înlocuire, atunci pot fi utilizați algoritmi FIFO sau RAND; dacă însă pot fi admise aceste costuri, atunci nu merită să se utilizeze un algoritm mai complex decât LRU sau FINUFO.

#### 4. Indicatori de performanță.

Intr-un cadru general, următorii indicatori de performanță ai sistemului pot fi considerați semnificativi:

- utilizarea UCP: procentajul timpului în codul căruia UCP este ocupată cu executarea unui lucru "util";

- capacitatea de tratare a sistemului (throughput) măsoară numărul mediu de lucrări executate în cadrul unei unități de timp;
- timpul de răspuns al sistemului: măsoară timpul de calcul mediu pentru terminarea unei lucrări.

Din păcate, însă, este foarte dificil a face o legătură directă între acești indicatori de performanță generali ai sistemului și performanța sistemului de memorii.

În această situație vom considera numai indicatorii ce au legătură directă cu performanța efectivă a ierarhiei de memorii.

#### 4.1. Proporția succeselor. Proporția eșecurilor.

Datorită structurii strict ierarhice a sistemului de memorii și a modului de lucru al algoritmilor de înlocuire a paginilor, putem analiza performanța sistemului prin considerarea separată a nivelurilor ierarhice, pornind de la  $M_1$ . Deoarece un anumit nivel al ILVM primește o cerere de aducere a unei pagini numai în situația în care informația dorită nu a fost găsită într-un nivel mai înalt al ierarhiei, fiecare nivel observă un șir diferit de referiri de pagină.

Fie  $X(i) = x_1(i), x_2(i), \dots, x_{\lambda_i}(i)$  șirul de referiri de pagină a unui program observat de  $M_1$ .

Notăm:

$\lambda_i$  = lungimea șirului de referiri de pagină;

$\sigma_i$  = grupul de pagini distincte în șir;

$\eta_i$  = numărul de pagini în  $\sigma_i$ .

De exemplu, pentru următorul șir de referiri de pagină:

$X(1)$ : A, B, C, B, C, A, C

unde, prin litere mari de tipar s-au reprezentat adrese logice de pagină, se obțin următoarele valori:

$$\lambda_1 = 7$$

$$\sigma_1 = A, B, C$$

$$\eta_1 = 3$$

Pentru un anumit șir de referiri de pagină  $X(i)$ , un nivel  $M_1$  al sistemului de memorii și un algoritm de înlocuire, definim șirul de referiri de aducere a paginilor  $X_a(i)$  secvența în timp a referirilor de pagină din  $X(i)$  care nu au fost găsite în  $M_1$ .

Fie  $\lambda_{ai}$  lungimea șirului  $X_a(i)$ .

Referirile de pagină, care au fost găsite în  $M_1$  le vom

numi succese. Numărul succeselor este numărul de referiri satisfăcute de  $M_1$  și este:

$$\text{nr. succese} = \lambda_i - \lambda_{ai}$$

Numărul de referiri de pagină ce nu au fost găsite în  $M_1$  este numit număr de eșecuri:

$$\text{nr. eșecuri} = \lambda_{ai}$$

În general, într-o ierarhie de memorii se urmărește maximizarea numărului de succese, sau, echivalent, minimizarea numărului de eșecuri. Este mai comod însă a considera raportul între numărul de succese (sau eșecuri) și numărul total al referirilor - se obțin astfel proporția succeselor și proporția eșecurilor:

$$S_i = \frac{\lambda_i - \lambda_{ai}}{\lambda_i} = 1 - e_i$$

$$e_i = \frac{\lambda_{ai}}{\lambda_i}$$

Fie  $X(1)$  un șir de referiri de pagină generat de UCP și aplicat nivelului  $M_1$  ca intrare (ierarhia este întotdeauna accesată la nivelul superior) și fie  $\Lambda$  lungimea acestui șir. ( $\Lambda \equiv \lambda_1$ ).

Proporția eșecurilor de sistem a unui anumit nivel este definită ca:

$$e_{si} = \frac{\lambda_{ai}}{\Lambda}$$

iar proporția succeselor de sistem, relativă la nivelul  $i$ , este:

$$s_{si} = 1 - e_{si}$$

Aplicînd determinările de mai sus la șirul de referiri de pagină  $X(1)$  generat de procesor și primit de  $M_1$ , constatăm că șirul de referiri de aducere a paginilor  $X_a(1)$ , generat de  $M_1$ , este de fapt șirul de referiri de pagină  $X(2)$  primit de  $M_2$ .

Prin repetarea succesivă a acestui proces, putem crea șiruri de referiri de aducere a paginilor și proporțiile respective de succese și eșecuri pentru fiecare nivel al ierarhiei.

Presupunînd că toate informațiile referite de program există în ierarhia de memorii, rezultă că suma proporțiilor suc-

ceselor de sistem este egală cu unitatea:

$$\sum_{i=1}^c s_{si} = 1 .$$

Există multe utilizări și interpretări posibile ale proporției succeselor  $s_i$ . O trăsătură comună a tuturor acestor aplicații este faptul că  $s_i$  asigură o legătură comodă între un model abstract al ILVM și sarcina de lucru reală a unui sistem de calcul (77).

Pentru un șir de referiri de pagină  $X(i)$  dat și un algoritm dat de înlocuire a paginilor, proporția succeselor  $s_i$  depinde numai de capacitatea de memorizare a nivelului  $M_i$ . Această funcție este numită uneori funcția de succese  $s(c_i)$ . Ea reprezintă probabilitatea găsirii informației cerute pentru fiecare referire de memorie, la o memorie de capacitatea  $c$ .

Funcția de eșecuri este definită corespunzător:

$$e(c) = 1 - s(c)$$

și reprezintă probabilitatea de a nu găsi informația cerută în cadrul unei referiri de memorie într-o memorie de capacitatea  $c$ .

O mostră de funcție  $e(c)$  este dată în figura 6.

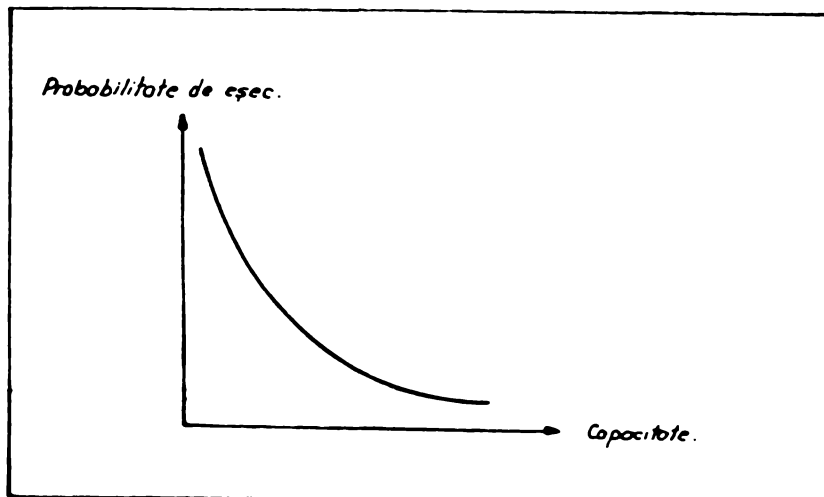


Fig.6. O reprezentare calitativă a unei dependențe  $e(c)$ .

Cunoașterea funcțiilor  $s(c)$  și  $e(c)$  permite tratarea unor probleme de optimizare ce apar în cadrul proiectării unui sistem de ierarhii de memorii, în legătură cu combinarea diferitelor tehnologii, ce au caracteristici diferite de cost-performanță (a se vedea secțiunea 5.2.1.).

#### 4.2. Timp de acces efectiv. Cost efectiv.

Indicatorii generali ai performanței unui ILVM sînt timpul

de acces efectiv  $t_{ef}$  și costul efectiv  $b_{ef}$ , definite astfel:

$$t_{ef} = t_1 s_{s1} + t_2 s_{s2} + \dots + t_l s_{sl} = \sum_{i=1}^l t_i s_{si}$$
$$b_{ef} = \frac{b_1 c_1 + b_2 c_2 + \dots + b_l c_l}{c_1 + c_2 + \dots + c_l} = \frac{\sum_{i=1}^l b_i c_i}{\sum_{i=1}^l c_i}$$

$t_{ef}$  și  $b_{ef}$  pot fi considerate caracterizînd întreaga ierarhie de memorii, echivalînd-o cu un sistem cu un singur nivel.

Din punctul de vedere al indicatorilor de cost-performanță pentru un proiectant trebuie să fie indiferentă alegerea între un dispozitiv de memorie cu o singură tehnologie și un singur nivel, cu timpul de acces mediu  $t_{ef}$  și costul/bit  $b_{ef}$  și un sistem ierarhic de memorii cu parametri de performanță ( $t_{ef}$ ,  $b_{ef}$ ).

În cazul că proiectantul sistemului necesită o memorie cu indicatorii ( $t, b$ ) și o astfel de tehnologie de bază nu există, el va încerca să construiască o ierarhie de memorii, astfel încît:

$$(t_{ef}, b_{ef}) = (t, b)$$

## 5. Evaluarea și optimizarea ILVM.

În timpul proiectării unei anumite configurații de sistem, proiectantul de calculatoare are două alternative principale: una de a simula sistemul și alta de a dezvolta un model matematic ce încorporează parametri principali de interes.

În continuare vom arăta modalitățile de aplicare a acestor tehnici în problemele de evaluare și optimizare a ILVM, comparînd utilitatea și avantajele lor.

### 5.1. Simulare.

În mod empiric, cu cît mai puțin este cunoscută comportarea sistemului, cu atît mai probabilă este necesitatea simulării. De asemenea, cu cît mai complicat este un sistem, cu atît mai microscopică, mai detaliată trebuie să fie simularea.

O abordare tipică în analiza ILVM a fost simularea unei varietăți de scheme, la diferite nivele de detaliere, cu scopul

./.

de a limita câmpul proiectelor -soluții posibile. Aceste simulări sînt rulate cu unele șiruri de referiri reale, ce sînt considerate a fi reprezentative pentru sarcina pe care sistemul o va trata, în eventualitatea că va fi implementat.

Sînt multe motive ce fac studiile de simulare a ILVM foarte lungi și detaliate:

a) este foarte dificil a caracteriza proprietățile statistice a programelor ce acoperă un mare domeniu de aplicații.

Prin urmare este necesar ca determinarea performanțelor unei anumite configurații de memorii să se facă pe baza șirurilor de referiri reale, obținute fie sintetic, fie din programe reale.

Trebuie subliniat că obținerea șirurilor de referiri din programele reale nu este deloc un proces ieftin. Nu numai că trebuie să fie disponibile echipamente hardware și software corespunzătoare pentru a înregistra succesiunea referirilor, dar de asemenea volumul de informații de memorat este foarte mare; un program FORTRAN tipic poate genera 40.000 referiri. După selecția unei anumite dimensiuni de pagină, acest șir de referiri trebuie adus la forma unui șir de referiri de pagină;

b) procedura de aducere și înlocuire a paginilor nu se pretează a fi tratată în formă analitică.

Procesul de transfer al paginilor în cadrul ierarhiei de memorii este dependent de proprietățile statistice ale încărcării sistemului și nu este posibil a reprezenta acest proces în formă analitică. Chiar dacă am asocia șirului de referiri de pagină un anumit tip de comportament probabilistic, activitatea de transpunere în termeni matematici a acestui comportament nu este o sarcină ușoară;

c) algoritmul de înlocuire este probabil principalul factor ce face modelul analitic foarte dificil de formulat.

Chiar dacă sînt făcute presupuneri foarte stricte asupra activității de paginare, este greu a formula un model ce ține seama într-un mod cantitativ de algoritmul de înlocuire.

A simula o ILVM cere, în mod obișnuit, tratarea fiecărei adrese singulare, cu actualizarea corespunzătoare a tabelului

adresei paginilor, a informațiilor ce stau la baza activității algoritmului de înlocuire, a girurilor pentru tratare UCP și I/E etc.

#### 5.1.1. Tehnici de eșantionare.

Uneori pot fi propuse modele analitice, dar nu este posibil a obține soluții generale pentru model într-o formă compactă. Cazul apare frecvent când distribuțiile probabilistice ale unuia sau mai multor parametri sînt complexe sau nu pot fi exprimate în termeni matematici. În mod obișnuit într-o asemenea situație se utilizează metoda convențională Monte Carlo sau tehnici de eșantionare.

Fie  $X$  o variabilă aleatoare cu o funcție de densitate a probabilității arbitrară  $f(x)$ . Presupunem că se dorește a genera valori ale lui  $x$ , astfel ca aceste valori să urmeze distribuția prescrisă.

Fie  $F(x)$  distribuția de probabilitate a variabilei aleatoare  $x$ :

$$F(x) = \int_{-\infty}^x f(x) dx$$

Atunci, o valoare de eșantion a lui  $x$ ,  $x_0$ , poate fi obținută astfel:

$$x_0 = F^{-1}(R) \quad (a)$$

unde  $R$  este o variabilă aleatoare uniform distribuită în  $[0,1]$ .

Dacă funcția inversă pentru distribuția probabilității variabilei aleatoare arbitrare nu există, este întotdeauna posibil să se genereze eșantioane a acelei variabile aleatoare, prin înlocuirea relației (a) cu o expresie aproximativă.

De asemenea, am presupus că există disponibil un generator aleator cu distribuție uniformă.

Alte metode, în afara acestei metode directe, de generare a numerelor aleatoare urmînd o lege de probabilitate specificată, sînt:

- metoda respingerii, datorată lui von Neumann, 1951;
- metoda compunerii, propusă de Butler, 1956;
- metoda compunerii-respingerii, propusă de Butcher, 1961.

Descrierea acestor metode se poate găsi în tratate de



statistică.

Fie un șir de valori ale variabilei aleatoare  $x$ , generate conform uneia din metodele de mai sus.

$$(x_1, x_2, \dots, x_n)$$

Legea numerelor mari arată că:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n x_i = E(x)$$

Prin urmare, cu cât se dorește o exactitate mai mare, cu atât mai multe valori de eșantion ar trebui generate. Acesta este un motiv pentru care, chiar dacă modelul probabilistic pentru un anumit sistem poate fi propus, simularea este în general o metodă costisitoare.

Au fost propuse câteva tehnici pentru a grăbi convergența mediei unui grup de valori de eșantion la valoarea așteptată: unele din ele sînt explicate în detaliu de Shedler și Yang (150) în lucrarea lor ce se ocupă de unele aspecte ale simulării unui sistem de paginare.

#### 5.1.2. Tehnici de tratare pe principiul stivei.

O contribuție importantă în domeniul simulării unei ILVM a fost adusă de Mattson ș.a. (121). Metoda, denumită tratare pe principiul stivei, poate fi utilizată pentru determinarea timpului mediu de acces a unei ILVM generale, presupunînd că organizarea ierarhiei este complet asociativă sau grup asociativă (vezi secțiunea 6.2. a acestui capitol) și algoritmul de înlocuire utilizat este din categoria algoritmilor de stivă. Un algoritm de înlocuire este denumit de stivă dacă el produce o ordonare totală a tuturor paginilor referite anterior și utilizează această ordonare pentru luarea deciziilor de înlocuire. Ordonarea poate fi reprezentată ca o listă de priorități ce urmărește o relație de ordonare; pagina cu prioritatea cea mai mică este selectată pentru înlocuire. Exemple tipice de algoritmi de stivă sînt LRU și LFU în timp ce FIFO nu intră în această categorie.

Lucrarea consideră o organizare complet asociativă cu înlocuire LRU.

Fie  $X = \{x_1, x_2, \dots, x_t\}$  un șir de referiri de pagină ce servește ca intrare pentru ierarhie.

$\gamma_t$  reprezintă grupul paginilor distincte în  $X$ , iar  $\eta_t$  reprezintă numărul paginilor în  $\gamma_t$ .

Fie  $C$  o limită superioară a capacității memoriei  $M_1$  (în pagini);  $B_t(C)$  reprezintă grupul de pagini în  $M_1$  imediat după ce pagina  $x_t$  a apărut în șirul de referiri.

Faptul că LRU este un algoritm de stivă, implică:

$$B_t(1) \subset B_t(2) \subset \dots \subset B_t(\eta_t)$$

și

$$B_t(C) = \begin{cases} C & \text{pentru } 1 \leq C < \eta_t \\ \eta_t & \text{pentru } C \geq \eta_t \end{cases}$$

Pe baza proprietății de incluziune precedente, grupul de pagini  $\gamma_t$  poate fi ordonat într-o listă:

$$S_t = \{s_t(1) \quad s_t(2) \quad \dots \quad s_t(\eta_t)\} \quad \text{unde:}$$

$$s_t(i) = B_t(i) - B_t(i-1)$$

pentru  $i = 1, 2, \dots, \eta_t$

Grupul de pagini  $S_t$  este denumit stivă LRU și reprezintă conținutul lui  $M_1$  în orice moment  $t$ .

Fie  $C_t$  capacitatea critică, astfel ca:

$$x_t \in B_{t-1}(C)$$

dacă și numai dacă  $C \geq C_t$ .

Capacitatea critică pentru o pagină care nu a mai fost referită anterior este considerată arbitrar ca infinită.

Datorită modului în care este construit  $S_t$ ,  $C_t$  este pur și simplu poziția paginii  $x_t$  în stiva LRU;  $C_t$  este de asemenea numit distanță în stivă deoarece reprezintă poziția oricărei pagini referite anterior în stiva LRU.

Fie  $n(\Delta)$  numărul de ori, de care o anumită distanță în stivă  $\Delta$  apare la tratarea șirului de referiri  $X$ ; atunci numărul de ori de care o pagină este găsită în  $M_1$  se poate determina simplu:

$$N(C) = \sum_{\Delta=1}^C n(\Delta)$$

./.

De aici, proporția eșecurilor poate fi exprimată prin:

$$e(C) = 1 - N(C) / \Lambda$$

unde  $\Lambda$  este numărul total al paginilor în șirul de referiri.

Procedura de actualizare pentru stivă este simplă:

$$s_t(1) = x_t$$

$$s_t(i) = s_{t-1}(i-1) \quad \text{pentru } 2 \leq i \leq C_t \text{ și } C_t \neq \infty$$

$$s_t(i) = s_{t-1}(i-1) \quad \text{pentru } 2 \leq i \leq \eta_t \text{ și } C_t = \infty$$

Contribuția principală a acestei metode constă în simplitatea ei și posibilitatea obținerii proporției eșecurilor sau complementului ei într-o singură trecere a șirului de adrese. De semnalat este faptul că această valoare se poate obține simultan nu numai pentru capacitatea maximă  $C$  a lui  $M_1$ , dar și pentru orice capacitate mai mică decât ea.

Această metodă, cu mici modificări, se aplică la o ILVM cu orice număr de nivele, orice algoritm de stivă și de asemenea organizări grup asociative.

Deși par foarte atractive, tehnicile de stivă implică un volum foarte mare de calcule, deoarece stiva trebuie să fie actualizată la fiecare nouă referire în șirul de referiri de pagină. Dacă capacitatea limită superioară  $C$  este mare, după cum ne putem aștepta în mod obișnuit, această tehnică devine foarte scumpă.

În concluzie, simularea este necesităată ori de câte ori nu sînt disponibile tehnici analitice. Ea asigură rezultate a căror exactitate depinde de gradul de detaliere cu care este realizată; de obicei este costisitoare, atît în efortul de programare, cît și în timpul de calcul.

## 5.2. Modelare matematică.

### 5.2.1. Probleme de optimizare de programare nelineară.

Se consideră un sistem ILVM cu  $l$  nivele, fiecare nivel  $i$  fiind caracterizat de timpul de acces  $t_i$ , costul/bit  $b_i$  și capacitatea  $c_i$ .

Criteriul de optimizare ales în (35) este de a minimiza timpul de acces efectiv al ierarhiei  $t_{ef}$  și a satisface restricțiile privind costul total al sistemului și capacitățile, sau, echivalent, de a minimiza costul total al sistemului și a satis-

face restricțiile privind timpul de acces efectiv al ierarhiei  $t_{ef}$  și capacitățile.

Problema este următoarea:

Sînt date:

- capacitatea de memorizare  $c_1$ ;
- funcția de cost de tehnologie  $b(t)$ , considerată ca funcție de timpul de acces;
- costul total al sistemului  $b_s$

$$b_s = \sum_{i=1}^l b(t_i) c_i$$

- funcția de succese  $s(c)$  sau funcția de eșecuri  $e(c)$ , considerate dependente de capacitate (a se vedea secțiunea 4.1);

- numărul de nivele  $l$ .

Variabilele:

$$t_1, t_2, \dots, t_l$$

$$c_1, c_2, \dots, c_{l-1}$$

Să se minimizeze funcția:

$$t_{ef} = \sum_{i=1}^l e(c_{i-1}) t_i$$

și să se satisfacă restricțiile:

$$b = \sum_{i=1}^l b(t_i) \cdot c_i \leq b_s$$

$$t_i > 0 \quad \text{pentru } i = 1, 2, \dots, l \quad \text{și}$$

$$c_i > 0 \quad \text{pentru } i = 1, 2, \dots, l-1$$

Deoarece funcțiile  $s(c)$  (corespunzător  $e(c)$ ) și  $b(t)$  în cazul general nu sînt lineare, minimizarea se prezintă sub forma unei probleme de programare nelineară.

În (32) se presupune că funcția de eșecuri  $e(c)$  și cea de cost de tehnologie  $b(t)$  sînt funcții-puteri, și anume:

$$e(c) = c^{-\alpha} \quad (m)$$

$$b(t) = t^{-\beta} \quad \text{și} \quad (n)$$

./.

Aceste presupuneri par restrictive, însă la nivelul actual al analizei și datorită insuficienței unor date, ele ne permit o înțelegere mai bună a comportării ILVM și posibilitatea de a determina influența anumitor parametri asupra acestei comportări. De altfel, aproximația (n) este utilizată și în lucrarea (114) cu parametrul  $0,2 \leq \beta \leq 96$ , iar funcția putere (m) nu este mult diferită de proporția experimentală a eșecurilor, dată în (120).

#### 5.2.2. Utilizarea modelelor cu șiruri de așteptare.

În cadrul unui sistem de calcul cu multiprogramare, mai multe lucrări concurează pentru a utiliza resursele comune ale sistemului. Presupunând că numărul de cereri este mai mare decât numărul unităților de resurse comune, în mod necesar se formează în sistem șiruri. Asemenea șiruri de așteptare se formează și pentru procedura de utilizare a ierarhiei de memorii. Analizând comportarea acestor șiruri, pot fi obținute multe rezultate privind comportarea sistemului. În mod rațional, teoria șirurilor de așteptare a devenit unul din mijloacele importante ale analizei ILVM.

Am arătat mai înainte că caracterizarea statistică a unor parametri este o problemă foarte dificilă; de multe ori neavând nici o alternativă, se recurge la simulare. Foarte des însă, precizia cu care sînt obținute anumite rezultate nu reprezintă obiectivul principal, ci mai curînd se urmărește o înțelegere calitativă a modului cum sistemul este afectat de variațiile diferiților parametri. Pentru aceste tipuri de studii, modelele ce utilizează șiruri de așteptare sînt foarte utile.

Utilizarea modelelor cu șiruri de așteptare ca mijloc de analiză a avut și insuficiențe, precum:

(a) au fost analizate numai configurații restrînse și mai curînd specializate. Pentru proiectant a fost necesar să încadreze sistemul lui real în aceste modele și să facă în acest scop restricții foarte severe. Fiind dată pentru analiză o anumită configurație de sistem, procedura a fost de a examina diferite structuri de așteptare pentru care au fost obținute soluții matematice, sperînd ca una din aceste structuri să fie cumva corespunzătoare;

(b) soluția noilor structuri de așteptare a fost foarte nesistematică; în principal, bazați pe rezultate anterioare, se

testa o soluție ce apărca ca probabilă, pentru a determina dacă ea satisface ecuațiile de bază ale sistemului de așteptare. Dacă o asemenea soluție s-ar dovedi nepotrivită, printr-o selectare atentă repetată și analiza erorilor, s-ar urmări obținerea unei soluții corecte.

Până la obținerea unei soluții automate și bine înțelese, nu s-ar fi pus problema unei utilizări eficiente a sistemelor cu așteptare de către analistul de sistem.

O asemenea metodă a fost propusă și anume Irani și Wallace (101) au descris o metodă, prin care pot fi determinate automat soluții numerice pentru rețele arbitrare de așteptare cu timp de servire exponențial. (Notăm că într-un sistem de calcul toate distribuțiile timpului de servire sînt presupuse exponențiale). Acesta a fost un rezultat important, deoarece a făcut posibilă analiza într-un mod interactiv a diferitelor configurații de sistem. Limitarea acestei metode este aceea că pentru un număr mare de utilizatori solicitînd servirea sau o rețea mare de așteptare, trebuie să fie inversate matrici foarte mari, implicînd un volum important de calcule.

Un pas important în automatizarea soluției pentru rețelele cu așteptare sînt lucrările lui Chandy (32,33). El dă o metodă prin care pot fi determinate într-o manieră surprinzător de simplă, soluții algebrice a unor rețele de așteptare arbitrare cu timpi de servire exponențial.

O metodă pentru studiul ILVM utilizînd acest aparat al sistemelor de așteptare este dat în (136). Metoda este rapidă și flexibilă la schimbarea parametrilor sistemului. Astfel, se cercetează efectul schimbărilor în parametrii sistemului (nivelul de multiprogramare, numărul nivelelor de memorii și capacitățile lor, numărul canalelor, balanța activităților UCP și de I/E) asupra caracteristicilor sistemului (utilizarea diferitelor stații de servire, lungimea șirurilor de așteptare).

## 6. Realizări și cercetări în domeniul ILVM.

Scopul cercetărilor în domeniul ILVM este de a dezvolta ierarhii de memorii cu caracteristici cost-performanță

attractive. O cale simplă de a scădea considerabil parametrul de cost/bit este de a dimensiona nivelele ierarhiei într-un mod crescător pe măsură ce trecem de la nivele cu performanțe ridicate și cost ridicat la nivelele cu performanțe scăzute și cost scăzut (adică  $b_1 > b_2 > b_3, \dots$ , și  $c_1 < c_2 < c_3 \dots$ ).

Presupunând că referirile de adrese generate de UCP sînt distribuite uniform în timp și în domeniul de adrese, fiecare adresă ar avea o probabilitate egală de a fi referită în orice moment. Această probabilitate ar fi:

$$\text{Pr (ref)} = \frac{1}{c_1 + c_2 + \dots + c_l}$$

Astfel, proporția așteptată de succese a sistemului  $s_{si}^0$  pentru fiecare nivel  $i$ , este proporțională cu dimensiunea nivelului.

De exemplu:

$$s_{s1}^0 = c_1 / (c_1 + c_2 + \dots + c_l)$$

Și, deoarece am presupus că  $c_1 < c_2 < \dots < c_l$ , rezultă că:

$$s_{s1}^0 < s_{s2}^0 < s_{s3}^0 < \dots < s_{sl}^0$$

Astfel, funcția așteptată de succese pentru nivelul 1 domină (este aproximativ egală cu 1), deoarece am presupus că acesta este nivelul cu capacitatea cea mai mare. Referindu-ne la definiția timpului de acces efectiv al ierarhiei  $t_{ef}$ , putem stabili că el va fi aproximativ egal cu timpul de acces al nivelului cu performanța cea mai coborîată (1) deoarece toți ceilalți termeni în relația  $t_{ef}$  (secțiunea 4.2) ar fi neglijabili. Dacă această analiză ar fi adevărată, ierarhia noastră de memorii ar avea, în final, o performanță cu puțin mai bună decît nivelul de performanță cel mai coborît la o creștere modestă în preț - un rezultat nu deosebit de îmbucurător.

În realitate însă, ierarhiile de memorii nu se comportă în acest mod. A fost observat în mod empiric că programele reale își distribuie referirile lor la memorie astfel încît în decursul unui interval de timp este folosit numai un subset din informațiile disponibile. În cap.5 vom prezenta o analiză detaliată a acestui comportament.

După cum s-a arătat mai înainte, fiecare nivel al ierarhiei "observă" o altă trasă de adrese a programului. Nivelele înalte ale ierarhiei urmăresc mostrele de referire "microscopică" instrucție cu instrucție, pe când nivelele medii urmăresc mostre de referire mai mari, subrutină cu subrutină. Nivelele joase ale ierarhiei urmăresc referirile UCP, atunci când aceasta trece de la un subsistem la alt subsistem.

Determinarea valorilor  $s_i$  a proporției succeselor pentru diferitele nivele  $M_i$ , în cadrul însă mai restrâns al unei clase de ILW, numită ierarhie cu faze, este realizată în (77). Metoda folosită se bazează pe o generalizare a tratării pe principiul stivei (descrișă la 5.1.2.) numită tratare pe principiul stivei adaptată.

Vom prezenta acum, pe scurt, realizări și cercetări în domeniul ILW, marea majoritate referindu-se la ierarhii cu 2 și 3 nivele, deși, de exemplu, într-o carte a lui Lorin (116) este prezentată o ierarhie cu 7 nivele.

#### 6.1. Sisteme cu memorie virtuală.

Sistemele timpurii automate de memorii au fost bazate pe ierarhii cu două nivele de memorie cu miezuri - tambur (dispozitive similare celor din pozițiile 3 și 6 ale tabelului 1). Această tehnică a fost introdusă în sistemul Atlas (73,105) în anii 1960. De atunci a fost și este utilizată în multe sisteme contemporane. Astfel, memorii virtuale sînt oferite de sistemele IBM-370, UNIVAC-seria 70, DEC-10, Burroughs - seriile 500 și 700, unele sisteme CDC, Xerox-seria Sigma, Fujitsu-seria Facom, Amdahl 470 V/6 ș.a.

Performanța sistemelor cu memorie virtuală a fost studiată de numeroși cercetători: Belady (18), Coffman și Varian (40,159), Hatfield (88), Sayre (145). Intre rezultatele lui Coffman, de exemplu, a fost notat că deși raportul  $c_1/(c_1+c_2) = 0,25$ , proporția succeselor  $s_i$  depășește 95%. Hatfield a studiat performanța programelor de sistem, care au fost proiectate cu atenție și a determinat că pentru proporții ale  $c_1/(c_1+c_2)$  de 0,25 a fost posibil ca proporția succeselor să depășească 99%.

Există două abordări de bază pentru a obține efectul de memorie virtuală, segmentare și paginare.



IBM, CDC, Xerox și Univac au ales paginarea, Burroughs a implementat segmentarea.

Vom prezenta sumar aceste abordări.

#### 6.1.1. Memorie virtuală paginată.

Paginarea împarte memoria virtuală în blocuri (pagini) multiple de dimensiune fixă și egală, care sînt apoi aduse în memoria principală pe măsura necesităților.

Memoria paginată are un mare avantaj: programatorii nu mai trebuie să fie preocupați de dimensiunea programelor lor.

Partițiile în memoria virtuală pot fi suficient de mari pentru toate scopurile practice.

De exemplu, sistemul de operare utilizat în cadrul IBM System/370 - Operating System - Virtual Storage 2 (OS/VS2) are la dispoziție o capacitate de memorie virtuală de 16 milioane octeți. Într-o asemenea situație, întotdeauna vor exista partiții disponibile în memoria virtuală, indiferent de capacitatea memoriei reale. Sistemul de operare va plasa în memoria reală, la momentul respectiv, numai paginile necesitate de desfășurarea programului.

În aceste condiții, programatorii de aplicații își pot concentra eforturile asupra aplicației respective; programatorii ce se ocupă cu întreținerea programelor nu trebuie să se mai îngrijească de posibilitatea încadrării unui program modificat într-o partiție dată (ei măresc doar partiția respectivă dacă este necesar), iar programatorii de sistem nu mai au de înfruntat probleme legate de limitări de capacitate a memoriei și pot să se concentreze asupra administrării priorității lucrărilor.

Un alt avantaj important adus de acest tip de memorie virtuală constă în eliminarea fragmentării externe a memoriei (137). Problema fragmentării memoriei în cadrul unei ILVM este discutată în cap.3, secțiunea 1.1. Aici ne rezumăm a arăta că, în situația împărțirii memoriei în cadre de pagină, se creează posibilitatea folosirii integrale a spațiului de memorie; nu vor mai exista domenii libere de memorie reală (ce apar și se amplifică între partițiile unui sistem de operare convențional) ce nu pot fi folosite pentru a dispune în ele programe, deoarece sînt prea mici pentru acest scop.

Vom analiza în continuare factorii ce afectează performanța unui sistem cu memorie virtuală paginată și apoi căile de îmbunătățire a acestei performanțe.

6.1.1.1. Factori ce afectează performanța unui sistem cu memorie virtuală paginată.

Factorii ce afectează performanța unui sistem într-un mediu cu memorie virtuală paginată (pe lângă cei generali - ce se referă la un mediu cu memorie non-virtuală) sînt:

(1) viteza și numărul dispozitivelor de paginare.

Operația de transport a paginilor între memoria principală și cea auxiliară implică consumul unui anumit timp; acest timp este o funcție de caracteristicile tipului de dispozitive de memorii utilizate. Pentru un anumit tip dat de asemenea dispozitive poate fi calculată rata maximă de paginare, exprimată în numărul de defecte de pagină ce pot fi tratate într-un interval dat de timp.

Capacitatea maximă de paginare a unui sistem dat poate fi mărită prin utilizarea unor dispozitive de memorii auxiliare mai rapide sau prin utilizarea mai multor asemenea dispozitive.

(2) viteza UCP. O relație de neconcordanță între viteza UCP și viteza dispozitivelor de paginare poate conduce la situația în care UCP este obligată în mod frecvent să aștepte executarea unor operații I/E de paginare. Când cererile pentru operații de paginare sînt permise să apară mai frecvent decît rata de paginare pe care sistemul o poate asigura, astfel încît sistemul poate executa puțin sau chiar deloc lucrul util în afara celui legat de activitatea de paginare, sistemul este într-o situație numită thrashing.

Sistemele de operare lucrînd cu memorii virtuale supra-veghează activitatea sistemului, pentru a determina momentele în care activitatea de paginare devine excesivă. Într-un asemenea moment, este executată deactivarea unei lucrări. Ca urmare, cadrele de pagină asociate cu lucrarea deactivată devin disponibile și pot fi alocate altor lucrări pentru a reduce activitatea de paginare. Mai tîrziu, la reducerea suficientă a activității de paginare, lucrarea deactivată este reactivată.


Din cele de mai sus rezultă că UCP mai rapide impun utilizarea unor dispozitive de memorii auxiliare de paginare mai rapide pentru a putea asigura tratarea ratei mai mari a defectelor de pagină:

(3) capacitatea memoriei reale. Capacitatea memoriei reale prezentă în sistem influențează numărul de defecte de pagină ce apar, în cursul tratării unui șir de lucrări. Dacă capacitatea memoriei reale a sistemului este egală cu capacitatea totală a memoriei virtuale utilizată de către lucrările în execuție simultană, pentru aceste lucrări nu apare nici un defect de pagină. Când capacitatea memoriei reale este mai mică decât cea a memoriei virtuale utilizate, apar defecte de pagină.

Numărul total al defectelor de pagină care apar pentru un anumit șir de lucrări este influențat de raportul dintre memoria virtuală utilizată și memoria reală disponibilă. Presupunând că capacitatea memoriei virtuale utilizată în cadrul sistemului rămâne constantă, raportul memoriilor virtuală/reală poate varia, ca urmare a modificărilor în capacitatea memoriei reale efectiv disponibile pentru paginare. Aceste modificări sînt datorate variațiilor ce apar în timpul tratării șirului de lucrări, a numărului de pagini fixe din memoria reală (care nu sînt supuse - pentru un termen lung sau scurt, definit de sistemul de operare - activității curente de paginare). Capacitatea memoriei reale disponibile pentru paginare într-un moment oarecare este diferența între capacitatea memoriei reale a sistemului și capacitatea paginilor definite ca fixe.

Pe măsură ce raportul memoriilor virtuală/reală crește, de obicei crește și rata defectelor de pagină. Această creștere a ratei defectelor de pagină este lentă pe un interval, ca la depășirea unei anumite valori a proporției memoriilor, creșterea să devină rapidă. Figura 7 ilustrează o dependență generală între numărul defectelor de pagină și proporția memoriilor virtuală/reală. La reducerea capacității memoriei reale disponibile vor apărea mai multe cereri către dispozitivele de paginare. Dacă capacitatea memoriei reale devine prea mică, creșterea ratei defectelor de pagină poate depăși limita permisă. De aceea, pentru a obține un anumit nivel de performanță, în cadrul unei configurații

./.



(ce administrează o anumită capacitate de memorii virtuale și tratează un șir dat de lucrări), devine necesară utilizarea unei capacități mai mari de memorie reală în cazul utilizării unor dispozitive de paginare relativ lente, comparativ cu situația în cadrul utilizării unor dispozitive de paginare rapide;

(4) structura programului. Modul și frecvența de referire a paginilor în cadrul unui program au un efect considerabil asupra numărului defectelor de pagină ce apar la tratarea acestui program. Astfel, în cadrul unui program ce face în mod constant referiri la un mare număr de pagini diferite de instrucții și date pentru durate foarte scurte de timp, într-o manieră aleatoare, poate apărea o rată excesivă de paginare.

Majoritatea tipurilor de programe manifestă o localizare naturală în caracteristica referirilor, astfel încât ele pot fi structurate pentru a opera ca o serie de faze logice. În cazul cel mai simplu, de exemplu, un program poate consta din punct de vedere logic dintr-o fază de inițializare, o fază principală, una sau mai multe faze de tratare a excepțiilor și o fază de terminare.

Comportarea de acces a programelor va fi discutată în detaliu în capitolul 4, unde vom construi un model corespunzător al acestei comportări.

O pagină este definită ca activă, dacă în timpul executării unei faze logice, are o probabilitate mare de a fi referită de mai multe ori; o pagină pasivă este definită ca avînd o probabilitate mică de a fi referită mai mult decît o dată în cursul executării fazei.

O fază logică este însoțită de o activitate minimă de paginare la execuția ei cînd paginile ei active rămîn în memoria reală în timpul execuției lor, iar paginile pasive sînt aduse în memoria reală, la cerere. Un program utilizează memoria reală în modul cel mai eficient, cînd instrucțiile și datele active în cadrul fiecărei faze logice sînt conținute în numărul cel mai mic posibil de pagini;

(5) capacitatea memoriei virtuale.

Odată cu creșterea capacității memoriei virtuale uti-

lizată în sistem, crește de asemenea și numărul paginilor active și pasive pe care sistemul trebuie să le trateze. La o creștere dată a memoriei virtuale, proporția paginilor active și pasive depinde de modul în care este utilizată memoria virtuală suplimentară. Atâta timp cât este disponibilă suficientă memorie reală pentru a conține toate sau majoritatea numărului crescut de pagini active, creșterea în activitatea de paginare va fi necesitată în principal pentru paginile pasive și este relativ mică. Imediat ce utilizarea unei memorii virtuale mai mari determină ca numărul paginilor active să depășească în mod constant capacitatea memoriei reale, activitatea de paginare devine mai intensă. Crescând continuu numărul paginilor de tratat, activitatea de paginare poate depăși capacitatea de paginare maximă a sistemului, dacă nu are loc deactivarea unor lucrări (fig.7).




Fig.7. Efectul creșterii raportului capacităților memoriilor virtuală/reală asupra numărului defectelor de pagină.

În figura 7 prin activitate de paginare pasivă/activă s-a reprezentat activitatea de paginare, în cadrul căreia are loc în majoritatea timpului transportul paginilor pasive/active.

Pe măsura creșterii raportului capacităților memoriilor virtuală/reală crește și numărul defectelor de pagină, sistemul

trecînd de la o activitate de paginare pasivă la o paginare activă și se apropie de capacitatea maximă de paginare a sistemului.

Figura 8 ilustrează modul de variație al performanței sistemului în domeniile de paginare activă și pasivă, ținînd seama de toți factorii ce influențează performanța.

Utilizarea mărită a memoriei virtuale este avantajoasă pentru performanța sistemului pînă la un anumit punct. După acesta, pot fi utilizate capacități de memorie virtuală adiționale pentru tratarea unor funcții suplimentare la un cost variabil în performanța sistemului.

Performanța sistemului se menține la un nivel ridicat în întreg domeniul de paginare pasivă. Aceasta deoarece în acest domeniu există o activitate de paginare relativ redusă și de asemenea o probabilitate mare ca întregul sau majoritatea timpului consumat pentru tratarea paginării (timp UCP și I/E) poate fi superpoziționat cu alte prelucrări.




Fig.8. O curbă generală de performanță a unui sistem pentru un mediu cu memorie virtuală.


Pe măsură ce activitatea de paginare se intensifică, există o probabilitate mai mare ca tratarea UCP să fie oprită pentru a aștepta terminarea unei operații de paginare. În măsura în care UCP intră în starea de așteptare mai frecvent pentru a aștepta paginarea și o proporție mai mică din această activitate de paginare este superpoziționată cu alte proceduri de tratare, performanța sistemului scade.

Intr-un sistem real, proporția capacităților memoriilor virtuală/reală și rata defectelor de pagină variază în timpul tratării de sistem, deoarece capacitatea memoriei virtuale utilizată (din capacitatea totală disponibilă) și capacitatea memoriei reale disponibile pentru paginare variază. Cea mai bună performanță globală a sistemului este atinsă când activitatea de paginare se situează în majoritatea timpului în domeniul identificat în figura 8 ca domeniu de operare. O reducere mai semnificativă a performanței este observată când se atinge domeniul de activitate de paginare activă. O activitate de paginare activă ocazională poate fi considerată, în cazuri de excepție, ca acceptabilă. O paginare activă mai frecventă poate fi executată pentru a realiza o funcție dorită, ce nu justifică schimbarea configurației sistemului. Însă, când activitatea de paginare în sistem este situată în mod constant la punctul în care are loc deactivarea unei lucrări, trebuie făcute schimbări în configurația sistemului pentru a îmbunătăți performanța. Astfel de schimbări pot fi mărirea capacității memoriei reale, utilizarea unui număr mai mare de dispozitive de memorie auxiliară de paginare sau a unor dispozitive mai rapide, sau instalarea unei UCP mai rapide.

6.1.1.2. Căi de îmbunătățire a performanței sistemului cu memorie virtuală paginată.

Tinând seama de cerințele suplimentare de resurse, ce apar în cadrul unui sistem operând cu memorii virtuale, ca și de factorii noi ce afectează performanța unui asemenea sistem, studiile întreprinse în această direcție pun în evidență anumite măsuri care pot fi luate cu scopul de a îmbunătăți performanța sistemului sau de a atinge un optimum al acestei performanțe.

./.



Asemenea măsuri sînt:

(1) utilizatorul să selecteze judicios proporția între capacitatea memoriei reale și capacitatea memoriei virtuale, ținînd seama de viteza de calcul a UCP;

(2) selectarea unei dimensiuni de pagină, care să fie corespunzătoare capacităților sistemului de operare (problema dimensiunii de pagină este discutată în detaliu în capitolul 3, secțiunea 1);

(3) creșterea capacității sistemului de tratare a defectelor de pagină, în cazul în care activitatea de paginare conduce în mod constant la deactivarea unor lucrări. Această creștere poate fi realizată prin:

a) utilizarea unor dispozitive de memorie de paginare mai rapide;

b) utilizarea unui număr mai mare de dispozitive de memorie de paginare;

(4) utilizarea unui cod ce nu se modifică pe el însuși (precum cel produs de limbajul Assembler și compilatorii limbajului PL/1). Utilizarea unui asemenea tip de cod poate reduce volumul activității de transport a paginilor din memoria principală în cea auxiliară;

(5) utilizarea unor memorii tampon de I/E mai mari.

Suplimentar cu reducerea timpului total de I/E necesar pentru tratarea unui set de date (după cum se întîmplă și într-un mediu cu memorie non-virtuală), această măsură reduce numărul de cereri de I/E necesare pentru a trata setul de date și prin aceasta reduce timpul consumat de CPU pentru translatarea și execuția programului de canal în discuție.

Luarea acestei măsuri trebuie să țină seama de asemenea, de capacitatea memoriei reale existente în sistem;

(6) structurarea noilor programe de aplicații și restructurarea programelor de aplicații existente pentru a realiza operarea lor eficientă într-un mediu cu paginare (89,145). În realizarea acestei măsuri trebuie urmărită considerarea următoarelor patru aspecte:

a) programele trebuie modularizate;

b) modulele utilizate împreună trebuie dispuse, dacă este posibil, în aceeași pagină;



c) modulele utilizate rar trebuie grupate la sfîrșitul programelor;

d) adresele (marcajele) de salt trebuie menținute în apropierea adresei instrucției de salt, de preferat în aceeași pagină.

Se urmărește prin aceasta ca rutinele utilizate cel mai frecvent să fie conținute într-un domeniu al programului cît mai mic posibil și ca un procentaj mai ridicat al codului utilizat cel mai frecvent să fie rezident în memoria reală. Cu alte cuvinte, modificările grupează împreună codul cel mai frecvent utilizat. Determinarea codului cel mai frecvent utilizat se poate face "manual", prin considerarea numărului de ori de care un program execută un modul, sau automat, prin utilizarea unor pachete disponibile de optimizare a codului, precum Cotune, Fortune, Storage III. Analiza comparativă a eficienței acestor procedee este realizată în (145). Prin aplicarea acestei măsuri se poate realiza o reducere a operațiilor de paginare cuprinsă între 50 și 90%, conform unor aprecieri IBM;

(7) alocarea, în cadrul aplicațiilor în prelucrarea pe loturi a unei capacități de memorie reală, cuprinsă între o jumătate și o treime din necesitățile totale de memorie (9). Prin această măsură, aplicațiile critice vor fi tratate în condiții relativ bune, fără a degrada performanța altor lucrări în prelucrarea pe loturi.

Aplicațiilor de teleprelucrare li se alocă memorii pe baza nivelului lor de activitate. După ce au fost asigurate partiții și alocată memorie aplicațiilor critice, pot fi alocate restul programelor și partițiilor. Fiecare partiție ar trebui să primească suficientă memorie reală pentru a permite programului cel mai lung din cadrul grupului să se încadreze, în ceea ce privește raportul capacităților memoriilor virtuală și reală, într-un domeniu învecinat valorii de 4:1 (9). Fiecărei partiții îi trebuie asigurat un domeniu virtual suficient pentru a înmagazina programul cel mai lung. Dacă capacitatea memoriei reale este insuficientă pentru a asigura valoarea menționată a proporției capacităților memoriilor, numărul de partiții trebuie redus

corespunzător;

(8) utilizarea unui algoritm de planificare a priorităților ce permite paginarea numai pentru lucrările cu prioritatea cea mai înaltă, în cazul apariției situației de thrashing;

(9) utilizarea a două câmpuri suplimentare (a câte 1 bit) asociate fiecărei intrări în tabelul de pagini, obținându-se o reducere suplimentară a interferenței datorate activității de paginare. Un asemenea câmp este cel numit "pagină modificată", ce este poziționat 1 la încălcarea paginii în memoria internă și este poziționat 0 la prima instrucție de scriere, ce face referire la această pagină. Dacă pagina ce trebuie înlocuită nu a fost modificată în timpul utilizării ei (câmpul de modificare fiind poziționat 0) ea nu mai este transferată înapoi spre memoria auxiliară, ci este pur și simplu ștearsă.

Al doilea câmp denumit "pagină utilizată" este utilizat la descrierea statistică a frecvenței de utilizare relativă a paginilor. Acest câmp este poziționat 1 la orice referire a paginii respective; la anumite intervale o rutină a sistemului de operare examinează acest câmp, notează starea lui și îl poziționează 0. Pe baza valorilor acestui câmp se pot lua decizii privind înlocuirea unei pagini (secțiunea 3.4);

(10) utilizarea unei proceduri de paginare fracționată.

Posibilitatea de a transfera din memoria virtuală în cea reală fracțiuni de pagini ar conserva memoria reală și ar reduce sarcina de cicluri furate<sup>\*)</sup>, impusă prin activitatea de paginare, care este deosebit de risipitoare, în cazul în care părți mari ale paginilor nu sînt folosite. S-ar crea astfel și posibilitatea ca programatorii să poată scrie programe mai eficiente, decît acelea a căror dimensiune este un multiplu întreg al dimensiunii paginii utilizate de sistemul de operare;

---

\*) furt de cicluri (cycle-stealing) - tip comun de obținere a ciclurilor de memorie pentru transferurile I/O, în care UCP este blocată unul sau mai multe cicluri, dacă este necesar, de către un transfer I/O pentru a permite ca datele să fie introduse sau extrase din memorie, "furînd" astfel cicluri ale UCP. Acest tip de operare încetinește funcționarea UCP, căci aceasta are mai puține cicluri utilizabile într-o unitate de timp.

(11) utilizarea, în cadrul sistemului, a mai multor dimensiuni distincte de pagini. În acest mod se realizează utilizarea mai eficientă a capacității memoriei reale și, ca și mai sus, se creează posibilitatea producerii unor programe mai eficiente;

(12) analiza ciclurilor programului.

Compilerul împarte programul în blocuri de instrucții și cercetează interacțiunea lor. Intenția este de a recunoaște cicluri și de asemenea cicluri incluse în alte cicluri, cu scopul de a permite simplificarea ciclului cel mai interior. Compilerul rearanjează instrucțiile astfel încât să permită ciclului încadrarea într-o singură pagină (sau mai multe pentru un ciclu lung), ce ar fi situate, în timpul executării ciclului, în memoria reală.

O analiză a cauzelor ce conduc la apariția situației de thrashing în activitatea de paginare și recomandarea unor măsuri de prevenire a ei pot fi găsite în (55).

#### 6.1.2. Memorie virtuală segmentată.

În schema de segmentare Burroughs sistemul de operare împarte codul obiect produs în segmente logice de program, corespunzător specificațiilor făcute de programator.

Fiecare program constă dintr-un segment de bază nesuperpoziționabil și segmente asociate superpoziționabile (overlayable).

Segmentul de bază conține toate domeniile de date, secțiunile cu fișiere I/E și toate celelalte domenii ale programului ce sînt, în orice mod, subiect de modificări; de aceea pentru un program activ segmentul de bază trebuie să fie rezident în memoria principală. El trebuie să prevadă legarea cu celelalte segmente dispuse într-o memorie auxiliară cu acces direct. Deoarece codul de program situat în această memorie auxiliară nu este niciodată modificat, segmentele nebazice active anterior nu trebuie să fie transferate înapoi în memoria auxiliară, în situația cînd un nou segment este adus în memoria principală. Această metodă de segmentare își găsește un echivalent în tehnicile de programare standard rădăcină/superpoziție în folosință de mulți ani.

Memoria virtuală paginată utilizează, după cum am văzut, blocuri mici - pagini - de informații, ce trebuie să fie manipulate între memoria virtuală și cea reală.

Cu scopul de a evita cheltuielile mari, implicate de tra-

terea software a numeroaselor cereri de I/E ale schimbului continuu de pagini, producătorii de sisteme de memorie virtuală paginată au găsit necesar să implementeze porțiuni semnificative ale acestui mecanism în hardware.

Burroughs a implementat memoria virtuală segmentată în software, utilizând segmentul rădăcină ca fundament.

Deoarece segmentele non-rădăcină nu sînt niciodată transferate înapoi în memoria virtuală, activitatea de thrashing este un fapt aproape imposibil în cadrul acestui sistem.

Avînd în vedere însă că numai codul nemodificabil poate fi memorat în memoria virtuală, există în mod potențial o mare risipă de memorie, în special deoarece domeniile tampon trebuie să fie menținute chiar atunci cînd fișierele nu sînt referite.

Pe de altă parte, software-ul Burroughs necesită alocarea continuă a spațiului în memoria reală, implicînd alocarea unui spațiu egal cu dimensiunea segmentului celui mai mare al programului. Dacă acest spațiu nu poate fi rezervat în memoria reală, execuția programului nu poate fi inițiată. Datorită, însă, Master Control Program - MCP, șansele ca programul să fie în situația de a nu putea fi rulat, ca urmare a lipsei de memorie continuă, sînt reduse semnificativ, datorită facilității numită sistem de comprimare a memoriei.

Comprimarea memoriei este inițiată automat de MCP. Cînd o lucrare se termină, MCP examinează șirul lucrărilor în așteptare pentru a determina dacă una dintre ele s-ar încadra în domeniul eliberat. Dacă da, acea lucrare este inițiată; dacă nu, lucrările în tratare sînt deplasate (comprimate) în memorie, pentru a ocupa domeniul eliberat. Spațiul făcut disponibil de către lucrările comprimate este continuu și este alocat unei noi lucrări. Astfel, programatorii, deși nepreocupați de cerințele generale de memorie ale unui program, trebuie să ia în considerație cerința de nemodificare a segmentelor, dimensiunea absolută a segmentu-

lui celui mai mare și dimensiunea relativă a restului de segmente. Segmentul cel mai mare trebuie să se încadreze în spațiul de memorie reală disponibilă pentru program, pentru a obține posibilitatea de a apela la sistem. Segmentele trebuie să fie de lungimi aproximativ egale, pentru a evita risipa ce ar putea fi cauzată prin plasarea segmentelor mici în spațiul de memorie reală rezervat pentru segmente mult mai mari.

#### 6.2. Sisteme cache.

Sistemele cache sînt bazate pe o ierarhie cu două nivele: cache - principală (pozițiile 1 și 2 sau 3 din tabelul 1).

Primele sisteme descrise de acest tip folosesc ca unitate de transfer între cele două nivele ale memoriei cuvîntul.

Vom prezenta sumar două asemenea tipuri de sisteme:

(1) sistem cu memorie "slave".

Una din primele lucrări privitoare la ILVM (154) introduce conceptul de memorie slave.

Succesul cu care anumite memorii tampon operînd la viteze electronice a mărit viteza de execuție a anumitor funcții asociate cu controlul unor calculatoare convenționale, a condus la această idee. Sistemul propus combină o memorie cu miezuri cu ciclul de 1  $\mu$ s (slave) cu o memorie cu miezuri mai lentă cu ciclul de 3  $\mu$ s (memorie principală) cu scopul de a obține pentru combinația realizată a unui ciclu mediu ce se apropie de acela al memoriei slave. Termenul "slave" derivă din faptul că toate referirile la memorie sînt obținute de UCP din memoria slave; dacă o referire nu este găsită acolo, este adusă în memoria slave din memoria principală. Sînt propuse două scheme de organizare.

Una se aplică la cazul unei memorii slave de capacitate mică (32 cuvinte): cuvintele din memoria principală sînt transpuse în cuvinte ale memoriei slave, astfel încît nu este necesară nici o organizare asociativă. Această organizare, rapidă și simplă, are unele dezavantaje, ce vor deveni clare mai tîrziu.

A doua schemă de organizare, cunoscută ca partiție - slave, se referă la o memorie - slave mare, de 32 K. În această organizare, cîteva blocuri de program își divid memoria-slave;

(2) sistem cu memorie look-aside.

A devenit un fapt cunoscut că programele nu-și distribuie aleator referințele lor în spațiul adreselor, ci au tendințe să opereze în anumite domenii de informații. Memoria look-aside a fost creată pentru a face uz de această proprietate cu scopul de a crește rata de instrucții a calculatoarelor convenționale.

Acest tip de memorie este format din registre asociative. Fiecare registru asociativ conține o cheie formată din două părți. Partea de adresă conține adresa cuvântului pe care registrul îl memorează și partea de uz conține unele informații în legătură cu algoritmul de înlocuire utilizat de către sistem (10). Dacă partea de adresă a cheii în registrul asociativ corespunde adresei unei anumite referiri, o astfel de referire este obținută din memoria look-aside; dacă nu se poate stabili nici o corespondență, atunci acea referire este obținută din memoria principală, ce constituie al doilea nivel al ierarhiei.

Selectarea cuvântului ce trebuie înlocuit cu scopul de a dispune noua referire, este făcută conform unui algoritm de înlocuire, cablat în sistem.

Toate registrele asociative, sînt examinate simultan, așa că întârzierea provocată este mică.

Cu această structură au fost obținute unele rezultate încurajatoare, principalul fiind următorul. Dacă un calculator convențional dispune de o memorie principală cu miezuri cu ciclul de 1  $\mu$ s, 128 registre asociative sînt suficiente pentru a obține un ciclu efectiv de memorie pentru combinație de 350-400 ns.

Cercetările ulterioare au pus problema utilizării ca unitate de transfer între cele două nivele de memorii a blocului, format din mai multe cuvinte. La prima vedere poate să nu apară să fie prea avantajos a transfera din  $M_2$  în  $M_1$  mai mult decît un cuvînt odată; dacă timpul pentru a transfera un anumit număr de cuvinte crește linear cu numărul de cuvinte, (ca în cazul unei memorii look-aside) transferarea cîtorva cuvinte odată ar fi o risipă, numai dacă toate cuvintele transferate nu vor fi

referite în viitorul apropiat. Dacă însă un grup de cuvinte (un bloc) poate fi transferat din memoria principală cu cheltuieli de timp mici, situația este diferită. Motivul pentru care se urmărește utilizarea unei unități de transfer formate din mai multe cuvinte rezidă în natura programelor de calculator și anume în faptul că o referire dată este probabil de a fi urmată de o alta, care este localizată fie secvențial, fie în imediata ei vecinătate în memoria principală.

Pentru a realiza transferul unui bloc de cuvinte din  $M_2$  în  $M_1$  este necesar de a crea o lățime de bandă suficientă. Aceasta se poate obține prin creșterea dimensiunii căii de date și prin intercalare. Intercalare înseamnă că  $M_2$  este împărțită în câteva module de memorie și că mai multe referiri consecutive sînt memorate succesiv în fiecare modul.

În continuare vom da o descriere și comparare calitativă a diferitelor organizări posibile ale memoriei  $M_1$ .

Există patru scheme:

(1) organizarea în sector. Ambele memorii  $M_1$  și  $M_2$  sînt împărțite în sectoare, a căror dimensiune este de câteva ori mai mare decît dimensiunea selectată a blocului. Fiecare sector este împărțit în blocuri; fiecărui sector din  $M_1$  îi este asociat un identificator cu scopul de a determina sectorul din  $M_2$  al cărui conținut îl păstrează.

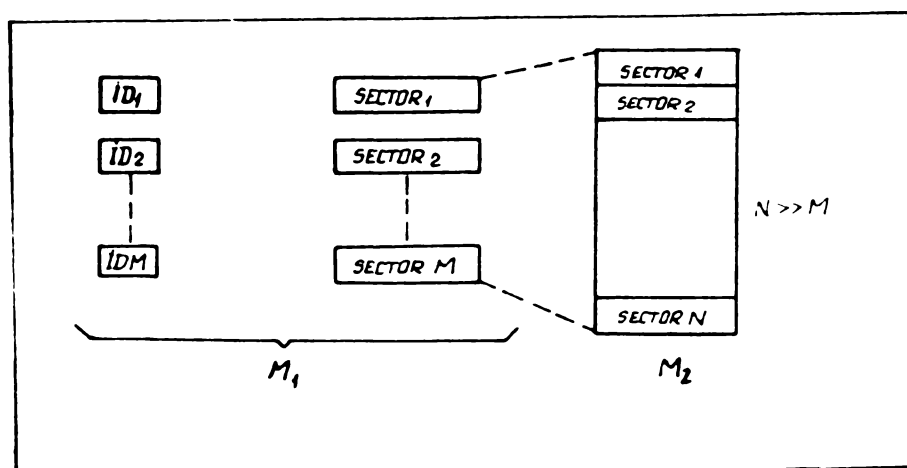


Fig.9. Organizare în sector.

Deoarece sectoarele sînt mari și  $M_1$  este, în general, doar o fracție din  $M_2$ , în  $M_1$  există relativ puține sectoare și

prin urmare puțini identificatori. Aceasta permite ca toți identificatorii să fie examinați asociativ simultan.

Într-un sector există, asociat cu fiecare bloc, un bit de "validitate" ce certifică prezența blocului în sectorul de care el aparține. Aceasta este realizată din următorul motiv: lipsa unui sector în  $M_1$  va provoca înlocuirea unui alt sector prezent în  $M_1$ , dar, deoarece dimensiunea unui sector este mare, blocurile sînt aduse în sector la cerere, unul cîte unul, în loc de a transfera întregul sector. Prin urmare, dacă un bloc este prezent într-un sector, bitul de validitate trebuie să fie poziționat 1.

Orice sector din  $M_2$  poate fi dispus în orice sector al lui  $M_1$ ; identificatorul stabilește adresa primului cuvînt într-un sector; la compararea cu succes, blocul dorit este identificat prin anumiți biți din compunerea adresei, iar cuvîntul sau octetul dorit de asemenea prin biți corespunzători din adresă.

Avantajul principal al acestor organizări constă în viteza cu care cuvîntul poate fi extras din  $M_1$ , ca o consecință a numărului redus de identificatori; acest lucru implică la rîndul lui cheltuieli mici de timp în execuția algoritmului de înlocuire.

Un dezavantaj serios apare din necesitatea de a înlocui un întreg sector, ori de cîte ori un sector nou trebuie să fie adus în memorie. Aceasta ar putea fi deosebit de critic dacă sistemul este multiprogramat sau dacă operează în regim cu diviziune în timp; în acest caz programele și-ar înlocui sectoarele unele altora și performanța s-ar înrăutăți.

IBM 360-35 a fost primul calculator ce a utilizat această schemă de organizare (115), căreia i-a fost dat numele de cache. Dimensiunea sectorului a fost aleasă de 64 blocuri a 16 cuvinte fiecare și dimensiunea lui  $M_1$  este de 16 sectoare.

(2) transpunere directă.

Ambele memorii  $M_1$  și  $M_2$  sînt împărțite în blocuri, a căror dimensiune este apropiată de dimensiunea optimă de bloc; fiecare bloc are un identificator, ce precizează biții de or-



din superior ai adresei primului cuvânt în bloc.

Disponerea blocurilor din  $M_2$  în  $M_1$  este realizată conform unei reguli anumite stabilite; corespunzător raportului între capacitățile memoriilor  $c_1$  și  $c_2$  vor exista mai multe sau mai puține blocuri din  $M_2$  ce vor concura pentru aceeași poziție în  $M_1$ .




Fig.10. Transpunere directă.

Fiind dată o anumită referire la memorie, există una și numai o poziție unde ea ar putea fi găsită în  $M_1$ ; identificatorul ce corespunde acestei poziții este examinat și dacă se constată concordanța, cuvântul sau octetul dorit este precizat cu ajutorul unor anumiți biți de ordin inferior din compunerea adresei. Dacă blocul nu este găsit în  $M_1$ , el este scos din  $M_2$  și transferat în  $M_1$  în locația de bloc corespunzătoare.

Avantajul principal al acestei scheme de organizare este faptul că nu este solicitată nici o cercetare asociativă și prin urmare adresarea  $M_1$  este foarte rapidă.

Există totuși o deficiență importantă a acestei organizări: este foarte posibil ca două referiri de memorie să conducă la transferuri din  $M_2$  în același bloc din  $M_1$ , ce ar implica necesitatea unui ciclu de  $M_2$  pentru o referire. Această situație este referită ca "dispută";

### (3) organizarea complet asociativă.

Ca și în cadrul schemei de organizare precedente, arbele  $M_1$  și  $M_2$  sînt împărțite în blocuri de dimensiune egală. Fiecărui

bloc din  $M_1$  îi este asociat un identificator. Acest identificator este alcătuit din biții de ordin superior ai adresei primului cuvânt prezent în bloc. Fiecare bloc din  $M_2$  poate fi transpus în orice bloc din  $M_1$ . Ca o consecință, pentru a stabili prezența unui anumit bloc în  $M_1$  este necesară examinarea tuturor identificatorilor. Această procedură de examinare este realizată într-o memorie asociativă într-un mod serial-paralel.

Din punctul de vedere al "disputei", aceasta este organizarea ideală; de asemenea, dacă câteva programe își divid  $M_1$ , fiecare ar putea avea  $M_1$  efectivă maximă cu acest mod de organizare.

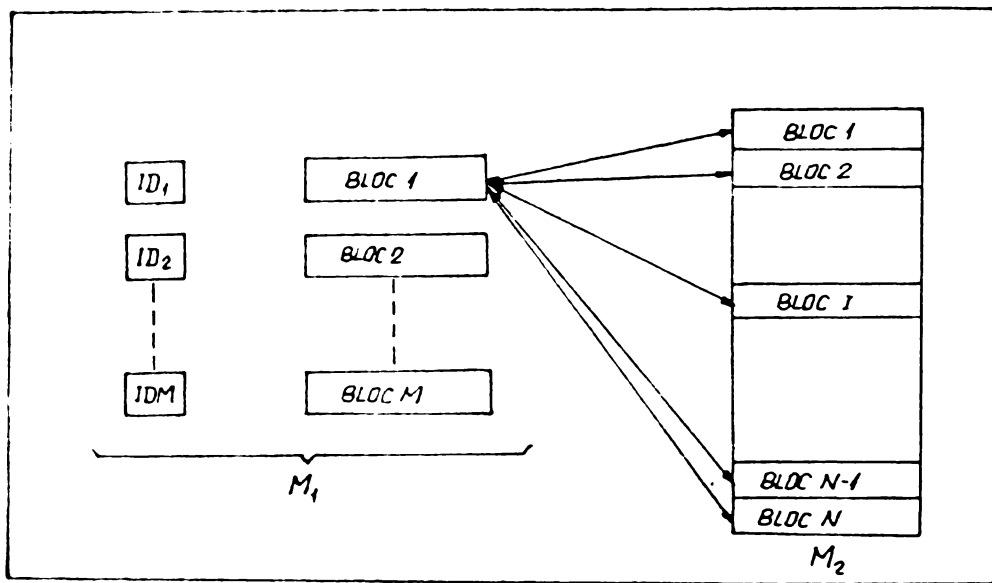


Fig.11. Organizare complet-asociativă.

Singura deficiență a organizării complet asociative este timpul cerut pentru cercetarea asociativă pentru toți identificatorii; în particular, dacă  $M_1$  este foarte mare, cheltuielile implicate ar putea fi prohibitive.

(4) organizare grup-asociativă.

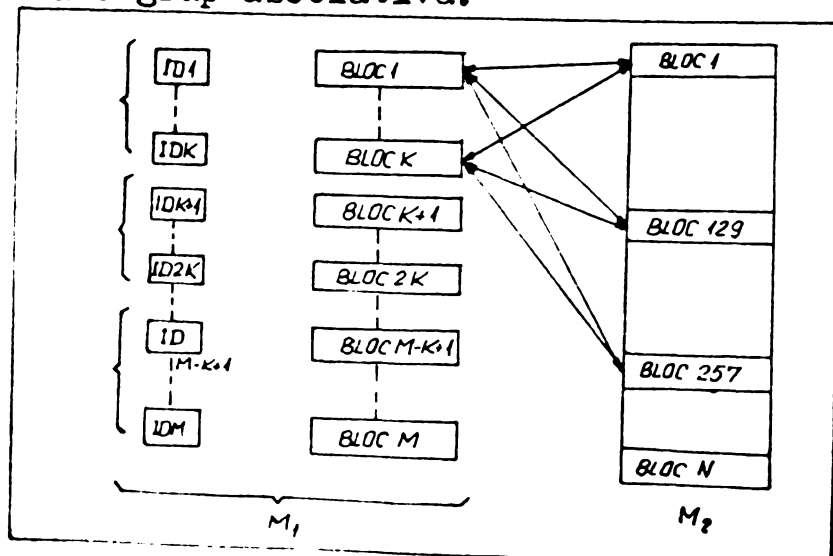


Fig.12. Organizare grup-asociativă.

Această organizare combină tehnicile de transpunere directă și complet asociativă. Ambele  $M_1$  și  $M_2$  sînt împărțite în blocuri de dimensiuni egale. Blocurile din  $M_1$  sînt clasificate în grupuri de blocuri, fiecare grup conținînd același număr de blocuri; blocurile din  $M_2$  dispun în blocurile lui  $M_1$  într-un grup anumit, dat. Deși este obligat să selecteze un anumit grup, blocul din  $M_2$  poate dispune în oricare din blocurile acestui grup.

Dacă numărul blocurilor cuprinse într-un grup este egal cu 1, schema este identică cu transpunerea directă. Dacă pe de altă parte dimensiunea unui grup este egală cu dimensiunea  $M_1$ , se regăsește schema complet asociativă.

După cum poate fi văzut, această organizare reține avantajul transpunerii directe și a organizării complet asociative; dacă cheltuielile implicate în schema complet asociativă sînt mari, această organizare ar putea fi preferată.

Aceasta este organizarea folosită în ierarhia de memorii a calculatorului IBM 370/155 (104). În acest calculator dimensiunea fiecărui grup este de 4 blocuri a 8 cuvinte logice fiecare; numărul total de grupuri existente în  $M_1$  este 64.

Proiectanții acestor sisteme cache au reușit să reducă drastic proporția  $c_1/(c_1+c_2)$  pînă la 1% și să mențină încă proporția succeselor  $s_1$  la peste 90%.

Rezultate similare au fost publicate de Bell și Casasent (21), Mattson (120), Meade (124) și Seligman (148).

O îmbunătățire structurală, relativă la utilizarea memoriilor cache este realizată în cadrul sistemului ICL 2900 (100), instrucțiile și operanzii sînt adresați de către procesor din trei memorii rapide slave. Fiecare din aceste trei memorii există pentru a servi o anumită fază de tratare a lanțului de instrucții: prima memorie conține instrucții, a doua operanzi primi și ultima operanzi secunzi. Această organizare asigură o viteză sporită de tratare a lanțului de instrucții.

### 6.3. Sisteme cu trei nivele.

În literatură au fost publicate puține lucrări, ce să cuprindă cercetarea unor asemenea sisteme.

Au fost studiate însă cel puțin trei tipuri de astfel de ierarhii:

(1) ierarhie de memorii, bazată pe utilizarea dispozitivelor 2,3 și 9 din tabelul 1. Cea mai consistentă cercetare este cea întreprinsă la Universitatea Carnegie-Mellon (71). Rezultate au fost de asemenea publicate de Williams (166);

(2) ierarhie de memorii bazată pe utilizarea dispozitivelor 3,8 și 9 din tabelul 1. Cercetarea a avut loc în legătură cu exploatarea sistemului Multics din cadrul proiectului KAC al MIT. Ca o indicație a efectului ei, s-a arătat că noua strategie a condus la creșterea proporției succeselor  $s_2$  de la 20% la mai mult de 90%;

(3) ierarhie de memorii bazată pe utilizarea următoarelor dispozitive: primul nivel corespunde dispozitivului 3 din tabelul 1, nivelul secund corespunde la o combinație a dispozitivelor 8 și 9 și al treilea nivel poate fi aproximat prin dispozitivul 10 al tabelului 1. Deși din datele lucrării lui Considine și Weis (43) este imposibil să se calculeze proporțiile succeselor, rezultă totuși că pentru  $c_2/(c_2+c_3)=0,5$ ,  $s_2$  este foarte mare (aproapiat de unitate).

### CAP.3. ANOMALIA DIMENSIUNII DE PAGINA

#### 1. Alegerea dimensiunii paginii utilizate în cadrul unei ILMI.

Un parametru important al unei ILMI (din categoria celor de configurație - vezi cap.2 - secțiunea 3.2.) este dimensiunea paginii, unitatea de informații transferată între nivelele vecine ale ierarhiei. Intrucât acest parametru afectează performanța unei ILMI, s-a acordat o atenție deosebită determinării unei dimensiuni optime de pagină. Astfel s-a constatat că factorii principali ce influențează alegerea dimensiunii de pagină sînt (1) fragmentarea memoriei și (2) eficiența operației de transport a paginii.

##### 1.1. Fragmentarea memoriei.

Prin fragmentarea memoriei se are în vedere împărțirea memoriei disponibile într-un număr mare de blocuri, separate prin domenii ocupate (nedisponibile). Acest fenomen este de natură statistică și apare cînd blocuri de dimensiuni variabile sînt alocate în memorie și apoi eliberate după intervale variabile de timp.

După cum se observă în cadrul unor sisteme de operare convenționale, aceste spații nefolosite din memoria principală situate între partiții au tendința de a se dezvolta pe măsură ce sarcina de lucru zilnică se amplifică. Fiecare din aceste domenii libere disponibile este prea mic pentru a dispune în el unul din programele plasate în șirul de așteptare cerînd spațiu de execuție continuu de o anumită dimensiune, deși suma capacităților domeniilor libere este suficientă. Această situație conduce la scăderi în utilizarea memoriei utilizate, care este măsurată prin procentul din capacitatea totală a memoriei, a capacității memoriei ocupate de activitățile curente și există două alternative:

- (1) să se admită această utilizare mai scăzută a memoriei;
- (2) apelînd la o anumită cheltuială de resurse ale sistemului, să se realizeze reorganizarea conținutului memoriei astfel încît să se unească blocurile separate de memorie disponibilă.

După cum s-a arătat în secțiunea 6.1.2.a cap.2 o soluție de tipul (2) a fost adoptată în cadrul schemei de segmentare

Burroughs - funcția de comprimare a spațiului ocupat de lucrările în tratare și de formare a unui spațiu liber continuu din fragmentele mici dispersate este realizată de MCP-Master Control Program.

O lucrare ce se ocupă cu studiul fenomenului de fragmentare al memoriei este (137). Vom prezenta pe scurt conținutul și concluziile acestei lucrări.

Pentru cercetarea fragmentării memoriei s-a recurs la o serie de experimente de simulare. În cadrul modelului utilizat memoria principală este reprezentată printr-o listă de blocuri de diferite dimensiuni, fiecare element din listă fiind însoțit de o indicație, dacă blocul este ocupat și, în caz afirmativ, când va fi eliberat. Elementele vecine în această listă se referă la blocuri din memorie vecine fizic. Cererile de spațiu de memorie sînt caracterizate prin mărimea spațiului cerut și lungimea de timp cerută, ambele valori fiind alese din distribuții statistice. Sirul de cereri a fost considerat ca fiind ordonat și nu s-a căutat intercalarea unor cereri de spațiu mai mic, în situația în care cererea actuală nu putea fi satisfăcută.

Prin model s-a cercetat efectul diferiților factori asupra utilizării memoriei, caracterizată de capacitatea memoriei ocupate de cererile alocate. Unul din acești factori indică ce algoritm de plasare (strategia pentru a decide unde ar trebui alocată în memorie o cerere pentru spațiu de memorie) este utilizat în cadrul experimentului. În model au fost cuprinși trei algoritmi distincți de plasare:

(a) MIN - acest algoritm întreține o listă a blocurilor disponibile, ordonate după creșterea dimensiunii. O cerere de memorie este alocată în blocul cel mai mic disponibil, ce are o dimensiune suficientă pentru a satisface cererea. Blocurile ocupate de memorie nu sînt deplasate pentru a uni porțiunile separate de memorie disponibilă;

(b) ALIATOR - alegerea blocului pentru a aloca cererea se face în mod aleator din întreaga mulțime a blocurilor disponibile, ce sînt suficient de mari. La fel ca în cazul algoritmului (a), blocurile ocupate nu sînt deplasate;

(c) RELOC - de fiecare dată ce un bloc ocupat devine disponibil, blocurile alăturate la dreapta lui sînt deplasate astfel încît spațiul disponibil să fie mereu menținut într-un bloc continuu, la sfîrșitul memoriei. Fiecare cerere este alocată în memorie, începînd cu cuvîntul de la începutul acestui bloc disponibil.

Algoritmi MIN și ALEATOR au fost aleși ca fiind situați în apropierea celor două extreme ale spectrului algoritmilor de plasare fără relocare, în ceea ce privește complexitatea și nivelul performanței. Algoritmul RELOC a fost ales în special ca termen de comparație, indicînd cîștigul maxim posibil ce s-ar obține utilizînd relocarea.

Se consideră ca scăderi în utilizarea memoriei acele situații în care o cerere de memorie nu poate fi alocată în memoria principală, deși cererile deja alocate în memorie în acest moment nu ocupă în întregime memoria.

În lucrare se face distincția între două tipuri diferite de fragmentare a memoriei:

(1) fragmentare externă: scăderea în utilizarea memoriei cauzată de imposibilitatea de a face uz de toată memoria disponibilă, după ce ea a fost fragmentată într-un număr mare de blocuri separate. Astfel, diferența între utilizarea memoriei obținută în cadrul unui experiment utilizînd ca algoritmi de plasare MIN sau ALEATOR și cea obținută în cadrul unui experiment utilizînd algoritmul RELOC este datorată fragmentării externe, pe care cei doi algoritmi o cauzează;

(2) fragmentarea internă, ce se referă la scăderea în utilizarea memoriei cauzată prin rotunjirea unei cereri de memorie la o valoare de alocare, în locul unei alocări de numai exact numărul cerut de cuvinte.

Cererile de memorie au fost rotunjite la un multiplu (cel mai apropiat) a unei unități de alocare  $Q$ .




Fig.13 Memorie fragmentată

Pe măsura creșterii dimensiunii unității de alocare  $Q$ , fragmentarea externă se micșorează, dar se mărește fragmentarea internă; ea corespunde spațiului de memorie irosit în cadrul fiecărui bloc prin procesul de rotunjire a cererii de memorie.




Fig.14. Efectele rotunjirii cererilor de memorie

Figura 14 reprezintă o curbă reprezentativă a tipului de rezultate obținute. Ea a fost obținută în cadrul unui experiment utilizând o distribuție exponențială a dimensiunilor cererilor de memorie, cu o medie de 1024 cuvinte, dimensiunea memoriei fiind de 32.768 cuvinte.

Rezultate similare au fost obținute utilizând algoritmi MIN și ALEATOR și de asemenea pentru diferite distribuții și valori medii ale dimensiunilor cererilor de memorie.

Rezultatul cel mai interesant este că pe măsura creșterii lui  $Q$ , scăderea în utilizarea memoriei datorată fragmentării interne mărite are o valoare mai mare decât câștigul datorat fragmentării externe scăzute. Acest efect se datorează faptului că pe măsura creșterii dimensiunii unității de alocare se mărește de asemenea spațiul de memorie alocat, dar nefolosit (deci irosit).

### 3.2. Eficiența operației de transport a paginii.

Timpul  $t_{di}$  necesar pentru a deplasa o pagină între două nivele ale ierarhiei (de la nivelul  $i$  la nivelul  $i-1$ ) constă din:

- (1) timpul mediu de acces  $t_i$ ;
- (2) timpul de transfer:  $p_i/r_i$ ,  $p_i$  fiind dimensiunea paginii, iar  $r_i$  fiind rata de transfer, relativă la deplasarea



informațiilor între cele două nivele.

Dacă toate dimensiunile de pagină au fost alese pentru a prevedea volumul de informații  $p_i$  cerut de procesor, timpul de deplasare al paginii între nivele este:

$$t_{di} = t_i + p_i/r_i$$

Pentru referiri concrete, vom considera un sistem de memorii compus din dispozitivele 1, 3, 8, 9 și 10 din cadrul tabelului 1 (mai frecvent întâlnite la sistemele de calcul curente). În tabelul 2 au fost indicate timpul de acces și rata maximă de transfer pentru fiecare din aceste dispozitive:

Nr.	Dispozitivul	Timpul de acces aleator (sec.)	Rata max. de transfer (octeți, sec.)
1	RAM-TTL	$60 \cdot 10^{-9}$	$1 \cdot 10^8$
3	RAM-MIEZURI	$500 \cdot 10^{-9}$	$2 \cdot 10^7$
8	DISC CAPETE FINE	$8 \cdot 10^{-3}$	$3 \cdot 10^6$
9	DISC CAPETE MOBILE	$50 \cdot 10^{-3}$	$8 \cdot 10^5$
10	BANDA MAGNETICA	10	$6 \cdot 10^5$

Tabelul 2. Timpul de acces și rata de transfer a unor dispozitive de memorii

Examinînd tabelul 2 se constată că timpul de acces variază considerabil mai mult decît rata de transfer: timpul de acces acoperă 9 ordine de mărime, în timp ce rata de transfer doar 3.

Această diferență pune problema avantajelor posibile de obținut prin transferul, în cadrul unui singur acces, a unui volum sporit de informații. Astfel, dorim a stabili creșterea lui  $t_{di}$ , dacă, suplimentar la cei  $p_A$  octeți ai paginii, se realizează transferul a încă  $p_A$  octeți, imediat următori. Presupunînd că  $p_A$  este destul de mic, de exemplu 8 octeți (am ales această valoare ținînd seama de lățimea benzii de date între nivelele 1 și 2 ale unei ierarhii), creșterile corespunzătoare ale timpilor  $t_{di}$  sînt trecute în tabelul 3.

./.

Tabelul 3

Transport între nivele	Time transport pentru 1 bloc	Time transport pentru 2 blocuri	Creșterea procentuală a timpului de transport
3 la 1	0,9 $\mu$ s	1,3 $\mu$ s	44%
8 la 3	8003 $\mu$ s	8005 $\mu$ s	0,03%
9 la 8	50010 $\mu$ s	50020 $\mu$ s	0,02%
10 la 9	10000013 $\mu$ s	10000027 $\mu$ s	0,0002%

Creșterea timpilor de transport a paginilor.

Din tabelul 3 constatăm că creșterea procentuală a timpului de transport la transferul suplimentar a  $p_1$  octeți scade de la o valoare ridicată de 44%, obținută în cadrul transferului de la nivelul 3 spre nivelul 1, la o valoare mică de 0,00002% în cadrul transferului de la nivelul 10 la nivelul 9.

Această situație este deosebit de favorabilă, avînd în vedere comportarea localizată a programului (vezi secțiunea privind conceptul de localizare) și anume: avînd în vedere acest caracter de localizare în mostra de referiri a programului la spațiul adreselor ne putem aștepta ca probabilitatea  $p_r$  ca procesorul să facă referiri în intervalul de timp imediat următor la cei  $p_1$  octeți alăturați transmiși suplimentar să fie considerabil mai mare decît inversul dimensiunii spațiului de adrese logice. Astfel, pentru un nivel dat al ierarhiei, dacă probabilitatea  $p_r$  este mai mare decît creșterea procentuală a timpului de transport, este avantajos să transferăm  $p_1$  octeți suplimentari și prin aceasta să evităm necesitatea de a cheltui  $t_{c1}$  sec. pentru a transporta acești  $p_1$  octeți separat, mai tîrziu.

După cum rezultă din tabelul 3 aceste avantaje sînt substanțiale în cadrul transferurilor între nivelele mai joase ale ierarhiei, caracterizate în special prin timpi de acces lenți. Pentru nivelele superioare ale ierarhiei, în speță dispozitive de memorii cu timpi de acces medii rapizi, creșterea timpului de transport la transferul suplimentar a  $p_1$  octeți este considerabilă și avantajele posibile de obținut în urma acestui transfer mai voluminos sînt mult mai mici.

O ultimă observație. Deoarece creșterea procentuală a  $t_{di}$  descrește monoton ca funcție de nivelul dispozitivului de memorie, numărul de blocuri a câte  $p_1$  octeți, urmând a fi transferați ca o singură pagină, ar trebui să crească uniform. Astfel, în cadrul unei ILVM ar fi avantajos ca între dimensiunile de pagini  $p_i$  utilizate să existe relația de ordonare:

$$p_1 < p_2 < \dots < p_l$$

### 1.3. Alte considerații privind dimensiunea paginii.

#### Concluzii.

Joseph (102) cercetează variația proporției eșecurilor (vezi cap.2, secțiunea 4.1.) în funcție de numărul de pagini din program aflate în memorie (alocare), în cazul unor diferite dimensiuni de pagină: (32, 128 și 1024 cuvinte) - în fig.15. proporția eșecurilor e reprezentată într-o scară logaritmică.




Fig.15. Proportia eșecurilor.

Curbele reprezentate prin linii continue se referă la programe lungi, iar cele reprezentate prin linii întrerupte se referă la programe scurte; se observă însă că între ele nu există o diferență substanțială.

Un fapt important de constatat este cel, de exemplu, că o alocare de 5 pagini a 32 cuvinte fiecare, conduce la o propor-

ție a eșecurilor mai mică decât o alocare de 2 pagini fiecare a 1024 cuvinte. Deci în situația în care se dispune în memoria principală de un spațiu mic pentru alocarea unui program (lucru curent în sistemele cu multiprogramare), paginile de dimensiuni mici se prezintă ca mai avantajoase. În ceea ce privește dimensiunea de 1024 cuvinte, utilizarea unei asemenea dimensiuni de pagină aduce o îmbunătățire a performanței față de dimensiunile mai mici de pagină numai după ce numărul de pagini alocate în memorie depășește 5 (în cazul cercetat, o alocare de 5 K pentru un program de 8 K).

În figura 16 este reprezentată variația proporției eșecurilor în funcție de dimensiunea paginii, pentru un număr fix de cuvinte în memorie (alocare în cuv.). Din nou se observă clar că în timp ce pentru alocări mici de memorie este mai eficientă utilizarea unor pagini de dimensiuni mai mici, la o alocare de peste 4 K utilizarea paginilor mai mari tinde să devină mai eficientă.

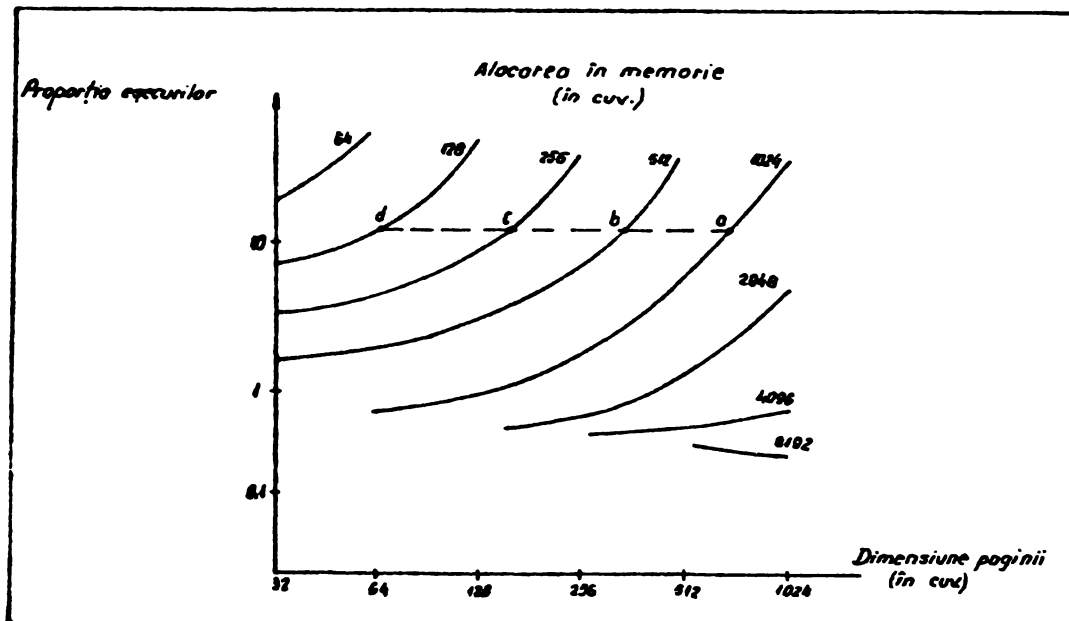


Fig.16. Variația proporției eșecurilor pentru diferite dimensiuni de pagină.

Astfel, din figura 16 rezultă că aceeași proporție a eșecurilor, realizată în cazul utilizării unor pagini cu dimensiunea de 1 K, poate fi obținută în cazul utilizării unui spațiu de memorie (alocare) considerabil mai mic și prin folosirea unor pagini de dimensiune mai mică (conform punctelor a, b, c și d pe curbele din figură).

./.

Un alt factor implicat în problema alegerii dimensiunii de pagină este consumul neproductiv de timp utilizat pentru gestiunea software a paginilor. Un asemenea consum se referă la:

- (1) întreținerea tabelelor descriptive de segmente și pagini, utilizate în cursul procedurii de translatare a adreselor;
- (2) actualizarea informațiilor privind prezența în memoria principală, utilizarea și modificarea paginilor;
- (3) gestiunea și alocarea memoriei paginate interne (prin activarea rutinei pentru execuția algoritmului de înlocuire) și externe;
- (4) detectarea unui defect de pagină, echivalent cu o cerere de introducere/extragere (I/E).

Ori de câte ori apare un asemenea eveniment, supervizorul trebuie să întreprindă următoarele acțiuni:

- selectarea rutinei de supervizor ce tratează comunicațiile de canal;
  - plasarea unei intrări în girul de așteptare a cererilor de I/E pentru canalul selectat;
  - memorarea stării programului ce generează defectul de pagină; aceasta echivalează cu memorarea conținutului contorului de instrucții, acumulatorului, registrelor aritmetice etc. într-un spațiu rezervat al memoriei UCP;
  - comutarea procesorului la o nouă lucrare;
- (5) detectarea terminării transferului unei pagini, echivalent cu un serviciu I/E.

Se întreprind următoarele acțiuni:

- actualizarea girului I/E al canalului respectiv;
- plasarea unei noi intrări în girul de așteptare al cererilor pentru utilizarea UCP;

Este dificil a determina acest consum neproductiv de timp implicat în gestiunea software a paginilor ca funcție de dimensiunea paginii. În cazul utilizării paginilor de dimensiune mică există mai multe pagini de cercetat, dar condiția pentru care se realizează această căutare poate fi distribuită în aceeași manieră pentru paginile mari și mici, astfel încât adâncimea de

cercetare ar fi aceeași. Deoarece se pot formula condiții ce ar favoriza oricare dimensiune, timpul software utilizat la înlocuirea unei pagini se presupune independent de dimensiunea paginii.

Cercetarea unor componente ale consumului neproductiv de timp, utilizat pentru realizarea hardware a operațiilor de paginare (timpul I/E consumat pentru accesul și transferul paginilor) și pentru gestiunea software a paginilor este realizată în (150): în lucrare este descris un model ce include explicit și acest consum, și care se referă la un sistem cu memorie virtuală cu două nivele, operând într-un mediu multiprogramat; nivelul de multiprogramare este fix. Consumul de timp asociat cu detectarea unei cereri I/E este presupus având o distribuție exponențială. Toate serviciile I/E și consumul de timp asociat cu terminarea unei I/E sînt presupuse constante. Rezultatele expuse indică că consumul neproductiv de timp nu este în nici un caz neglijabil; valoarea lui variază nelinear, în funcție de raportul timpilor medii de servire I/E și UCP.

În cadrul unui exemplu consumul neproductiv de timp echivalează cu cca.13% din timpul total de rulare și aprox. 12% din utilizarea totală a UCP.

Succesul sistemelor cache (cap.2 secțiunea 6.2.) indică, că principiul de localizare se aplică atît la scară microscopică, cît și la scară macroscopică a sistemelor cu paginare. Acest succes este un argument în favoarea utilizării unor dimensiuni mici de pagină.

În cadrul modelelor 155 și 165 ale sistemului IBM/370 dimensiunea blocurilor, utilizate pentru transferul între nivelele  $M_1$  și  $M_2$  ale ierarhiei de memorii, este de 32 octeți (8, 104).

Avantaje ale utilizării unor pagini de dimensiuni mici sînt discutate de asemenea în (12),(159); în (53) se constată îmbunătățirile importante aduse în utilizarea memoriei prin folosirea unor pagini de dimensiuni mici, de exemplu 200 octeți.

Putem constata de asemenea, că beneficiul utilizării unor dimensiuni mari de pagină, legat de eficiența operației de transport a paginii, este redus drastic prin introducerea recentă a unor noi tehnologii de dispozitive de memorii (memorii CCD, bubble și altele - vezi tabelul 1 din cap.2) cu timpi de acces rapizi.

Astfel introducerea acestor noi tehnologii în cadrul sistemelor utilizând ierarhii de memorii constituie un argument în favoarea utilizării unor dimensiuni mici de pagină.

Pe baza considerațiilor expuse se poate trage concluzia că folosirea unor pagini de dimensiuni mici conduce în sistemele moderne utilizând ILVM, la îmbunătățiri în utilizarea sistemului de memorii. Aceste îmbunătățiri se referă la utilizarea mai eficientă a spațiului de memorie și la valoarea mică a consumului neproductiv de timp utilizat pentru accesul hardware și gestiunea software a paginilor.

## 2. Anomalia dimensiunii de pagină

Anomalia dimensiunii de pagină se referă la raportul numărului de defecte de pagină generate în cadrul execuției unui program și utilizării succesive a două dimensiuni de pagină.

Ea a fost observată în cadrul unor experiențe pentru cercetarea eficienței reîmpachetării automate a programelor și secțiunilor de programe în pagini de memorie virtuală, astfel ca să se obțină o reducere a numărului de defecte de pagină. S-a pus problema dacă îmbunătățirile de performanță (mai puține defecte de pagină pentru o alocare fixă de memorie) obținute prin această împachetare pentru o anumită dimensiune de pagină, s-ar aplica de asemenea în cazul utilizării unor pagini de dimensiuni duble sau jumătate, fără a mai proceda la o reîmpachetare suplimentară. S-a cercetat efectul utilizării unor pagini de dimensiune dublă sau jumătate având în vedere faptul că dimensiunile paginilor utilizate în sisteme reale sînt puteri ale lui 2.

Rezultatele obținute în urma acestor studii au confirmat, în general, presupunerile cercetătorilor: anume, că și în cazul utilizării unor pagini, avînd dimensiunile dublă și jumătate față de dimensiunea de pagină folosită la aplicarea algo-

ritmului de împachetare, se pot constata îmbunătățiri ale performanței. Inșă, s-au obținut rezultate surprinzătoare la compararea numărului de defecte de pagină generate în cazul utilizării dimensiunilor de pagină de  $p$  octeți și, corespunzător,  $\frac{p}{2}$  octeți, surprinzătoare întrucât ele contrazic atât intuiția, cât și considerentele expuse în secțiunea precedentă. Anume, dacă un program este împărțit în pagini de dimensiunea  $p$  și apoi în pagini de dimensiunea  $\frac{p}{2}$ , execuția programului avînd pagini de dimensiune mai mică ar părea să implice un transfer mai mic de date, rezultînd din defecte de pagină. Motivul pentru acest lucru este că nu ne-am aștepta ca programul să folosească întotdeauna ambele jumătăți ale unei pagini de dimensiune mare.

Considerăm o primă situație, de extremă, în cadrul căreia ar fi întotdeauna folosită numai o jumătate din conținutul paginilor de dimensiune mai mare. În această situație lungimea secvenței paginilor, pentru ambele dimensiuni de pagină, ar fi aceeași; deoarece presupunem că unei cereri de pagină ( $i$ ) de dimensiune mare, i-ar corespunde o cerere de pagină mică ( $2i$ ) sau ( $2i - 1$ ). Dacă această corespondență de la paginile mari la cele mici ar implica întotdeauna aceeași jumătate a unei pagini mari ( $i$ ) șirul de referiri de pagină ar fi exact același (exceptînd renumerotarea) și ar rezulta același număr de defecte de pagină, pentru o alocare de același număr de cadre de pagină. Dar același număr de cadre de pagină implică jumătate de spațiu în cazul utilizării dimensiunii mici de pagină, așa că pentru un spațiu de aceeași capacitate, numărul de defecte de pagină ar fi considerabil mai mic. De asemenea, timpul pentru transferul paginilor ar fi mai mic, căci fiecare pagină este pe jumătate de lungă. Această situație favorizează în mod evident dimensiunea mai mică de pagină.

La cealaltă extremă (adică, cazul în care întotdeauna sînt utilizate ambele jumătăți ale unei pagini de dimensiune mare), la fiecare referire a unei pagini ( $i$ ) de dimensiune mare, secvența corespunzătoare a paginilor mici



referite ar fi  $(2i-1)$ ,  $(2i)$ . Sirul de referiri pentru paginile mici ar avea o lungime exact dublă, față de lungimea șirului de referiri de pagini mari; pentru aceeași capacitate de spațiu de memorie reală, numărul de defecte de pagini mici ar fi exact dublul numărului de defecte de pagini mari. Dar din nou, deoarece paginile mici sînt pe jumătate de lungi, numărul total de octeți transferați ar fi același. Consumul nereproductiv de timp ar fi mai mare pentru paginile mici, datorită creșterii corespunzătoare a timpului de acces și a timpului software asociat, cu actualizarea și căutarea în tabelele de pagini (creștere datorată dublării numărului de defecte de pagină).

Presupunem, deci că limita superioară efectivă a numărului de defecte de pagini mici este dublul numărului de defecte de pagini mari; de asemenea, presupunem că, pe măsură ce densitatea de utilizare a memoriei în cadrul unei pagini scade, raportul între numărul de defecte de pagini mici și numărul de defecte de pagini mari scade de asemenea. Ne așteptăm ca avantajul utilizării unei dimensiuni mici de pagină să crească pe măsură ce spațiul disponibil se micșorează.

Referindu-ne acum la rezultatele experimentale, ele au confirmat aceste presupuneri, în cazul unor programe caracterizate ca manifestînd o utilizare a memoriei de joasă densitate (o distribuție în timp aprox. uniformă de utilizare a spațiului de memorie reală alocat).




Fig. 17.




Fig. 18.

În figura 17 sînt reprezentate curbele caracterizînd variația numărului de defecte de pagină în funcție de alocarea de memorie (spațiu de memorie reală disponibil) pentru pagini de 2 Ko (linie continuă) și pagini de 4 Ko (linie întreruptă). Algoritmul de înlocuire utilizat a fost FIFO. Linia punctată reprezintă raportul între numărul de defecte de pagină pentru pagini de 2 Ko și numărul de defecte de pagină pentru pagini de 4 Ko. Prin linii orizontale sînt reprezentate raportul de 1:1 și raportul 2:1.

Din figura 17 rezultă că, pentru majoritatea valorilor capacității memoriei alocate, paginile de 2 Ko conduc la un număr mai mic de defecte de pagină decît paginile de 4 Ko. Numai în situația în care programului îi este alocat întreg spațiul de memorie pe care îl necesită, raportul defectelor de pagină tinde spre valoarea 2:1. Înălțimea la care se oprește curba reprezentînd acest raport indică raportul între numărul total de pagini de 2 Ko necesitate și numărul total de pagini de 4 Ko necesitate.

În figura 18 sînt reprezentate aceleași curbe, dar pentru un program caracterizat ca manifestînd o localizare puternică a utilizării memoriei (programul își distribuie în timp referirile la spațiul de memorie neuniform, localizat la anumite domenii). După cum se observă din figură, pe o porțiune considerabilă a domeniului de variație a memoriei disponibile și anume în jumătatea dreaptă a domeniului de variație - regiunea de activitate de paginare moderată și scăzută - utilizarea paginilor de 2 Ko conduce la un număr de defecte de pagină mai mare decît numărul de defecte de pagină rezultate prin utilizarea unor pagini de 4 Ko. Si - contrar așteptărilor intuitive - raportul dintre numerele defectelor de pagină, rezultate prin utilizarea unor pagini de 2 Ko și 4 Ko depășește valoarea de 2:1, limita superioară presupusă. O asemenea situație este definită ca reprezentînd anomalia dimensiunii de pagină.

Prin cercetarea unor șiruri de referiri de pagină se pot identifica situații ce modelează cazuri de apariție a

unei asemenea anomalii.

Fie, în acest sens, un sistem ierarhic de memorii cu două nivele, în cadrul căruia utilizăm, succesiv, pagini cu dimensiunea de  $p$  octeți și  $\frac{p}{2}$  octeți. Fie  $e_p$  și  $e_{\frac{p}{2}}$  numărul defectelor de pagină (eșecuri) obținute în cele două situații. Notăm prin  $\xi$  raportul acestor două numere:

$$\xi = \frac{e_{\frac{p}{2}}}{e_p}$$

Valorile posibile ale acestui raport  $\xi$  le repartizăm în trei domenii de interes:

$$(1) \quad \xi < 1$$

$$(2) \quad 1 \leq \xi \leq 2$$

$$(3) \quad \xi > 2$$

Vom discuta, pe rînd, aceste cazuri.

#### Cazul 1. $\xi < 1$

În acest caz, numărul de pagini aduse, prin defecte de pagină, în memoria principală în cazul utilizării paginii mai mici, este mai mic. De asemenea, ținînd seama și de faptul că transferul paginii de dimensiuni mai mici se realizează într-un timp mai scurt, rezultă că această situație ilustrează un caz de comportare de acces a programelor, ce favorizează utilizarea paginilor de dimensiuni mai mici.

În figura 19 este reprezentat un exemplu de asemenea caz. Similar cu secțiunea 4.1. din cap.2 am notat prin:

$\lambda$  = lungimea șirului de referiri de pagină;

$\gamma$  = grupul de pagini distincte în șir;

$\eta$  = numărul de pagini distincte în grupul  $\gamma$ .

Definim  $m_1$  ca fiind dimensiunea lui  $M_1$  exprimată în unități de pagină, recepționate de la nivelul inferior vecin. Astfel:

$$m_1 = \frac{c_1}{p_2}$$

La utilizarea unei asemenea dimensiuni de pagină de  $\frac{p}{2}$  octeți în loc de  $p$  octeți,  $M_1$  va conține de două ori mai multe pagini, fiecare din aceste pagini fiind însă pe jumătate de mare:

$$(m_1)_p = \frac{c_1}{p}$$

$$(m_1)_{\frac{p}{2}} = \frac{c_1}{\frac{p}{2}} = 2 \cdot \frac{c_1}{p}$$

deci:

$$(m_1)_{\frac{p}{2}} = 2 \cdot (m_1)_p$$

În convertirea șirului de referiri de pagină de dimensiuni  $p$  în șir de referiri de pagină de dimensiune  $\frac{p}{2}$ , pentru reprezentarea celor două jumătăți ale unei pagini  $A$  de dimensiune  $p$ , se folosesc adresele logice de pagină  $A_1$  și  $A_2$ .

Parametrii sistemului, în cazul utilizării paginii  $p$ :

- $\pi = A, B, C, A, B, C$
- $\lambda = 6$
- $\Gamma = \{A, B, C\}$
- $\eta = 3$
- $m_1 = 2$
- algoritm înlocuire: FIFO

Parametrii sistemului în cazul utilizării paginii  $\frac{p}{2}$ :

- $\pi = A_1, B_1, C_1, A_1, B_1, C_1$
- $\lambda = 6$
- $\Gamma = \{A_1, B_1, C_1\}$
- $\eta = 3$
- $m_1 = 4$
- algoritm înlocuire: FIFO

Pagină $p$	Sir referiri	A	B	C	A	B	C	
	Defecte pagină	≠	≠	≠	≠	≠	≠	
	Conținut $N_1$	1	2	3	1	2	3	
Pagină $\frac{p}{2}$	Sir referiri	A <sub>1</sub>	B <sub>1</sub>	C <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	C <sub>2</sub>	
	Defecte pagină	≠	≠	≠				
	Conținut $N_1$	1	A <sub>1</sub>	B <sub>1</sub>	C <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	A <sub>2</sub>
		2		A <sub>1</sub>	B <sub>1</sub>	B <sub>2</sub>	B <sub>2</sub>	B <sub>2</sub>
		3			A <sub>1</sub>	A <sub>2</sub>	A <sub>2</sub>	A <sub>2</sub>
4						A <sub>2</sub>	A <sub>2</sub>	

Rezultate:

- $e_p = 6$
- $e_p = 3$
- $\xi = \frac{3}{6} = 0,5$

Fig.19. Exemplu pentru cazul 1.

În exemplul din fig.19 raportul  $\xi = 0,5$  ceea ce înseamnă că numărul de pagini aduse prin defecte de pagină a fost redus la jumătate, prin folosirea dimensiunii de pagină mai mică. Rezultatul se referă evident la acea situație de extremă, discutată mai sus, în cadrul căreia programul folosește doar prima jumătate din conținutul paginilor de dimensiune mai mare. Un asemenea tip de rezultat poate fi așteptat de la un program ce manifestă o comportare de referiri destul de răsleață și nelocalizată. Astfel, în cadrul unui sistem tipic cu paginare cu două nivele, este adusă în memoria principală o pagină cu dimensiunea de 4096 octeți la prima referire pe care o face programul la această pagină. Dacă în intervalul de timp următor programul nu face alte referiri la această pagină, s-a creat o situație în care s-au adus în memoria principală multe date, dar au rămas nefolosite. În aceste circumstanțe utilizarea lui  $M_1$  ar putea fi îmbunătățită prin păstrarea unei colecții mai mari și mai diversificate de pagini, deși fiecare pagină ar fi mai mică.

#### Cazul 2. $1 \leq \xi \leq 2$

Acesta este un domeniu de tranziție. Pentru  $\xi = 1$  utilizarea paginilor mai mici va fi mai avantajoasă, deoarece numărul de defecte de pagină fiind același în ambele cazuri, totuși timpul consumat pentru transferul paginilor mai mici va fi mai scurt. Pentru  $\xi = 2$  utilizarea paginilor mai mici va conduce la un număr dublu de defecte de pagină. Dublarea acestui număr conduce la creșterea corespunzătoare a timpului consumat pentru accesul hardware și gestiunea software a acestor pagini. De aici rezultă comportarea mai bună, în această situație, a paginilor de dimensiune mai mare.

Punctul de tranziție poate fi determinat pe baza următoarelor considerente. Timpul de tratare a unui defect de pagină este compus din timpul consumat pentru transferul datelor, timpul de acces al dispozitivului de memorii, unde rezidă pagina respectivă și timpul software implicat în tratarea întreruperii generate de un defect de pagină și determinarea paginii ce urmează a fi înlocuită (algoritmul de înlocuire). Presupunând că performanța dispozitivului de memorii și procedura generală de paginare sînt identice pentru ambele dimensiuni de pagină, timpul de acces  $t_a$  va fi același pentru ambele pagini. Timpul de transfer este  $t_t$  pentru pagina de dimensiune mare și  $\frac{1}{2} \cdot t_t$  pentru pagina de dimensiune pe jumătate. În ceea ce privește consumul de timp software  $t_s$  implicat în înlocuirea unei pagini, conform celor discutate în secțiunea 1.3 a acestui capitol, se presupune același în ambele cazuri.

În fig. 20 este reprezentat un exemplu al acestui caz pentru care valoarea raportului  $\xi = 2,0$  deci se observă dublarea numărului de defecte de pagină în cadrul utilizării unei dimensiuni mai mici de pagină. Un asemenea tip de rezultat ar putea fi așteptat de la programe ce manifestă o comportare în mostra de referiri la memorie densă, localizată și secvențială.

Parametrii sistemului, în cazul utilizării paginii  $p$ :

- $x = A, A, B, B, C, C$
- $\lambda = 6$
- $\gamma = \{A, B, C\}$
- $\eta = 3$
- $m_1 = 2$
- algoritm înlocuire FIFO

Parametrii sistemului, în cazul utilizării paginii  $\frac{p}{2}$ :

- $x = A_1, A_2, B_1, B_2, C_1, C_2$
- $\lambda = 6$
- $\gamma = \{A_1, A_2, B_1, B_2, C_1, C_2\}$
- $\eta = 6$
- $m_1 = 4$
- algoritm înlocuire FIFO

Pagina p	Sir referiri	A	A	B	B	C	C
	Defecte pagină	≠		≠		≠	
	Conținut $M_1$	1	A	A	B	B	C
		2			A	A	B
Pagina $\frac{p}{2}$	Sir referiri	$A_1$	$A_2$	$B_1$	$B_2$	$C_1$	$C_2$
	Defecte pagină	≠	≠	≠	≠	≠	≠
		1	$A_1$	$A_2$	$B_1$	$B_2$	$C_1$
		2		$A_1$	$A_2$	$B_1$	$C_1$
	Conținut $M_1$	3			$A_1$	$A_2$	$B_1$
		4				$A_1$	$A_2$

Rezultate:

- $e_p = 3$
- $e_{\frac{p}{2}} = 6$
- $\xi = \frac{6}{3} = 2,0$

Fig. 20. Exemplu pentru cazul 2.

Intuitiv, rezultatul obținut pentru raportul  $\xi = 2,0$  este cazul cel mai defavorabil, căci în cazul acesta sîntem nevoiți să aducem întotdeauna în memoria principală ambele jumătăți  $A_1$  și  $A_2$  ale fiecărei pagini originale mari A, prin aceasta pierzînd toate beneficiile utilizării unei dimensiuni mai mici de pagină  $\frac{p}{2}$  și cauzînd un număr dublu de defecte de pagină. Inșă această observație bazată pe intuiție nu e corectă: cazul  $\xi = 2,0$  nu este cel mai defavorabil.

Cazul 3.  $\xi > 2$

În acest al treilea domeniu, utilizarea paginilor de  $\frac{p}{2}$  octeți ar conduce la apariția unui număr mai mare decît dublu de defecte de pagină decît în cazul utilizării paginilor de p octeți și, ca urmare a acestui lucru, este defavorizantă.

Parametrii sistemului, în cazul paginii p:

- $x = A, B, A, B, C, C, B, A, A, C, C$
- $\lambda = 11$

- $T = \{A, B, C\}$
- $\eta = 3$
- $m_1 = 2$
- algoritm de înlocuire FIFO

Parametrii sistemului, în cazul utilizării paginii  $\frac{p}{2}$

- $x = A_1, B_1, A_2, B_2, C_1, C_2, B_1, A_1, A_2, C_1, C_2$
- $\lambda = 11$
- $T = \{A_1, A_2, B_1, B_2, C_1, C_2\}$
- $\eta = 6$
- $m_1 = 4$
- algoritm de înlocuire FIFO

Pagina p	Sir referiri	A	B	A	B	C	C	B	A	A	C	C
	Defecte pagină	≠	≠			≠			≠			
	Conținut	1	A	B	B	B	C	C	B	A	A	C
	$M_1$	2		A	A	A	B	B	B	C	C	C
Pagina $\frac{p}{2}$	Sir referiri	A <sub>1</sub>	B <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	C <sub>1</sub>	C <sub>2</sub>	B <sub>1</sub>	A <sub>1</sub>	A <sub>2</sub>	C <sub>1</sub>	C <sub>2</sub>
	Defecte pagină	≠	≠	≠	≠	≠	≠	≠	≠	≠	≠	≠
	Conținut	1	A <sub>1</sub>	B <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	C <sub>1</sub>	C <sub>2</sub>	B <sub>1</sub>	A <sub>1</sub>	A <sub>2</sub>	C <sub>1</sub>
	$M_1$	2		A <sub>1</sub>	B <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	C <sub>1</sub>	C <sub>2</sub>	B <sub>1</sub>	A <sub>1</sub>	A <sub>2</sub>
		3			A <sub>1</sub>	B <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	C <sub>1</sub>	C <sub>2</sub>	B <sub>1</sub>	A <sub>1</sub>
		4				A <sub>1</sub>	B <sub>1</sub>	A <sub>2</sub>	B <sub>2</sub>	C <sub>1</sub>	C <sub>2</sub>	B <sub>1</sub>

Rezultate:

- $e_p = 4$
- $c_p = 11$
- $\xi = \frac{11}{4} = 2,75$

Fig.21. Exemplu pentru cazul 3.

În fig.21 se ilustrează un model de referiri la memorie ce conduce la un raport al numărului de defecte de pagină de 2,75. Alte asemenea exemple de șiruri de referiri de pagini, ce conduc la  $\xi > 2$ , utilizând ca algoritmi de înlocuire atât FIFO, cât și LRU, sînt date în (33).



### 3. Considerații finale. Necesitatea unor studii suplimentare

Anomalia dimensiunii de pagină a fost detectată în cadrul unor studii legate de posibilitatea obținerii unor îmbunătățiri suplimentare ale performanței unui sistem ierarhic de memorii prin utilizarea unor dimensiuni mai mici de pagină. Anume, contrar așteptărilor, numărul de defecte de pagină, apărute în cazul utilizării unei dimensiuni de pagină de  $\frac{p}{2}$  octeți depășește valoarea dublă a numărului de defecte de pagină, apărute în cadrul execuției programului și utilizării unei dimensiuni de pagină de  $p$  octeți.

Anomalia descrisă în (28) a fost constatată pentru valori ale dimensiunii de pagină cuprinse între  $p = 2 K_0$  și  $p = 16 K_0$ . Însă din considerarea exemplilor date în secțiunea precedentă, exemple ce modelează cazuri de apariție a anomaliilor de pagină, se poate constata că apariția anomaliilor este legată de moștră și șirul de referiri de pagină și nu de dimensiunea paginii. Ne putem deci aștepta la o astfel de anomalie și pentru dimensiuni mici ale paginii (de 64 și 32 octeți). Rezultă că anomalia dimensiunii de pagină poate fi întâlnită atât la calculatoarele ce folosesc hardware de relocare, pentru translatarea adreselor, cât și la cele ce utilizează memorii locale (cache).

Anomalia dimensiunii de pagină afectează toți algoritmi de înlocuire utilizați în prezent. Există o excepție și ea se referă la algoritmul MIN, descris de Belady (20), care conduce la numărul minim de defecte de pagină, pentru orice șir de referiri. Se poate ușor arăta (33) că acest algoritm nu poate produce un număr mai mare decât dublu de defecte de pagină, pentru o dimensiune de pagină redusă la jumătate. Interesul pentru acest algoritm este de natură teoretică numai, căci implementarea practică a acestui algoritm este greu de realizat. Anume, algoritmul necesită cunoașterea exactă a întregului șir de referiri la memorii, generat la execuția lui, înainte de execuție. Ori realizarea acestei condiții este practic imposibilă pentru un program, căci acesta poate interacționa dinamic cu mediul (intrări și ieșiri variabile în timp și ca volum) și cu resursele sistemului (utilizarea unor resurse software și hardware ale sistemului

într-un mod greu de precizat apriori, mai ales într-un mediu multiprogramat sau cu diviziune în timp).

În ceea ce privește interesul prezentat de algoritmul MIN, acesta constă în următoarele:

După cum s-a arătat în (18), fiind date un program caracterizat de șirul lui de referiri de pagină și dimensiunea memoriei reale alocate, este util să se cunoască numărul minim de defecte de pagină necesare pentru a rula programul, cu scopul de a evalua diferite configurații de memorii și scheme de gestiune a paginilor. De exemplu, eficiența unui algoritm de înlocuire a paginilor este definită ca raportul dintre numărul minim de defecte de pagină și numărul de defecte de pagină generate în cadrul utilizării unui anumit algoritm. Algoritmul MIN este o metodă pentru a determina numărul minim de defecte de pagină. Anume, algoritmul descris în (18) tratează șirul de referiri generat de program și, pentru o anumită dimensiune fixă a memoriei reale alocate, determină numărul minim asociat de defecte de pagină prin construcția, însă numai după o întârziere necesară și variabilă, a stărilor memoriei și tranzițiilor lor.

Algoritmul MIN cu mai multe valori descris în (20) permite obținerea în mod practic simultan a numerelor minime de defecte de pagină pentru întregul domeniu de alocări posibile de memorie reală, eliminându-se astfel dezavantajul algoritmului MIN, descris în (18) și care, la un moment dat, avea ca obiect o singură dimensiune de memorie. Lucrarea (20) prezintă, de asemenea, o posibilă implementare hardware a algoritmului MIN cu mai multe valori și anume un dispozitiv care, atașat unui calculator cu memorie virtuală, produce în mod continuu la ieșire un șir de valori ale capacităților de memorie minimă (LMC), în timp ce calculatorul execută programul respectiv. O valoare  $p$  a LMC are următorul sens: înainte de a fi referit, elementul șirului de referiri de pagină asociat cu această ieșire era conținut în memoria de capacitate  $p$  sau mai mare și de aceea, în cazul referirii la memoria de capacitate mai mică decât  $p$ , produce un defect în pagină. Pe baza șirului de valori a LMC și a alocării

reale se poate determina numărul minim de defecte de pagină.

În final, anomalia dimensiunii de pagină a fost constatată pentru programe manifestând un caracter localizat de utilizare al memoriei și anume în regiunea de activitate scăzută de paginare.

Aceasta este starea prezentă în cunoașterea acestei probleme. Anomalia dimensiunii de pagină a fost descrisă, dar nu cunoaștem nici o lucrare dedicată studiului acestei probleme și clarificării factorilor implicați în ea. Ca atare, lipsește o înțelegere mai precisă a mecanismului de apariție.

În aceste condiții rezultă necesitatea unor studii suplimentare care să cerceteze mai îndeaproape această problemă.

Importanța unor asemenea studii rezultă din următoarele considerente. Pe baza cunoașterii mecanismului de apariție al acestei anomalii, se vor putea elabora metode sau procedee de prevenire a apariției. Acest lucru se va dovedi de interes practic imediat. El va permite obținerea unor îmbunătățiri suplimentare în gestiunea unui sistem ierarhic de memorii prin utilizarea unor dimensiuni reduse de pagină, fără riscul unui consum mare de timp neproductiv datorat activității exagerate de paginare.

În încheiere câteva considerente privind posibilitatea apariției anomaliei dimensiunii de pagină în cazul unei programări structurate. S-a arătat că această anomalie a dimensiunii de pagină s-a detectat în cazul utilizării, pentru un program structurat pentru o anumită dimensiune de pagină  $p$ , a unei pagini de dimensiune înjumătățită,  $\frac{p}{2}$ . Pentru a beneficia de avantajele utilizării unei dimensiuni reduse de pagină și a nu mai recurge la o nouă restructurare a programului pentru o asemenea nouă dimensiune, este posibil să se ruleze programul structurat inițial în noile condiții, dar adoptând măsuri de evitare a apariției anomaliei. Evident este posibilă și soluția de a recurge la o nouă restructurare a programului pentru situația utilizării noii dimensiuni de pagină. Alegerea uneia din aceste soluții este dependentă de facilitățile hardware și software ale sistemului concret considerat.

#### CAP. 4. MODELE ANALITICE ALE COMPORTĂRII DE ACCES A UNUI PROGRAM

##### 1. Modele existente.

Modelele analitice de bază ale comportării de acces a unui program studiate pînă în prezent, sînt funcția de timp de existență (17) și modelul de grup de lucru (52). Le vom prezenta în continuare.

##### 1.1. Funcția de timp de existență.

În cadrul sistemelor ce utilizează o gestiune dinamică la cerere a memoriei, este dispusă în memoria de execuție doar o fracțiune dintr-un program. Apoi, pe măsură ce sînt necesitate proceduri sau date suplimentare, acestea sînt încărcate în memorie dinamic. Această schemă creează o secvență alternantă de intervale de execuție ( $e$ ) și întîrzieri ( $u$ ).

Intr-un sistem dat, la un anumit moment în timpul execuției unui anumit program, în domeniul de memorie alocat acestui program există o mulțime particulară de unități informaționale ce sînt asociate programului. Volumul și conținutul acestui domeniu de memorie alocat determină timpul de execuție ce va fi realizat pînă la apariția necesității unor informații suplimentare (defect de pagină). În lucrarea (17), Belady și Kuehner fac presupunerea că lungimea medie a intervalelor de execuție ( $e$ ) este funcție doar de mărimea spațiului de memorie ocupat.

Funcția de timp de existență, introdusă în lucrarea amintită, stabilește o relație între lungimea medie a intervalelor de execuție ( $e$ ) și dimensiunea memoriei ( $s$ ), care este alocată programului pentru desfășurare.

Factori ca modul de programare și tipul problemei, întîlnite în cadrul unor programe concrete, ca și algoritmul de înlocuire utilizat de sistem, influențează valorile locale ( $e$ ), dar nu sînt de natură să modifice comportamentul general al funcției de timp de existență. Asupra acestui comportament se pot face unele considerații intuitive. Astfel, dacă alocarea de memorie este mică, fracțiunea de program dispusă în memorie va realiza intervale de execuție foarte scurte. Dacă însă alocarea permite dispunerea întregului program în memorie, intervalul de execuție mediu este de ordinul timpului total de

rulare. Ar fi de așteptat ca această capacitate de execuție să fie monoton crescătoare între aceste extreme.

Ipoteza cea mai simplă relativă la modul în care sînt distribuite referirile la memorie ale unui program, este că aceste referiri urmează o distribuție aleatoare.

Notăm cu:

$r$  - domeniul de memorie, exprimat în pagini, referit de către program;

$s$  - alocarea de memorie, exprimată de asemenea în pagini  
(  $s < r$  )

Atunci poate fi arătat că numărul așteptat de referinți consecutive la memorie, înaintea apariției unui nou defect de pagină, este:

$$e = \frac{q}{1 - q} = q + q^2 + q^3 + \dots$$

unde:

$$q = \frac{s}{r}$$

$e$  reprezintă deci lungimea medie a unui interval de execuție, între două defecte succesive de pagină, exprimată în unități de referiri la memorie a unui program, manifestînd o distribuție aleatoare a referirilor la memorie.

Funcția de mai sus poate fi reprezentată printr-o curbă convexă, ca în fig.22.




Fig.22. Funcția de timp de existență pentru accese aleatoare.

Referirile la memorie ale programelor reale nu urmează însă o distribuție aleatoare. Forma mai generală a unei funcții de timp de existență mai realistă este reprezentată în fig.23 cu linie

continuă.




Fig.23. Funcția generală de timp de existență.

Unle observații au arătat că pentru multe programe, relația între  $e$  și  $s$  este neliniară și că o porțiune a ei poate fi aproximată prin:

$$e = k_1 \cdot s^{k_2}$$

Relația de mai sus este ea însăși o aproximație, iar determinarea valorilor pentru constantele  $k_1$  și  $k_2$ , astfel încât să se obțină o corespondență satisfăcătoare cu un anumit program real, este o a doua aproximație. În fig.23 este de asemenea reprezentată - prin linie punctată - aproximarea propusă în (17).


În acest model efectul dimensiunii paginii nu este considerat.

### 1.2. Modelul de grup de lucru.

Acest model este bazat pe recunoașterea unei proprietăți importante a comportării programelor și anume localizarea. Localizarea este proprietatea ca, în decursul oricărui interval de execuție, programul va favoriza unele din paginile lui într-o măsură mai mare decât pe altele. Factorii ce justifică această proprietate sînt discutați în secțiunea ce se referă la analiza comportamentului localizat al unui program (secțiunea 2 a cap.5).

Grupul de lucru de informații  $W_2(t, Z)$  a procesului  $p$  la timpul  $t$  este definit în (52) a fi colecția de informații pe care procesul  $p$  le-a referit în decursul intervalului de timp

virtual  $(t - \tau, t)$ . Ideea este ilustrată în fig.24.



timp virtual pentru  
procesul p

colecția de informații referite în acest  
interval constituie  $W_p(t, \tau)$

Fig.24. Definierea grupului de lucru.

Astfel, informațiile referite de proces în timpul ultimilor  $\tau$  unități de timp virtual ale execuției lui alcătuiesc grupul lui de lucru.  $\tau$  este numit parametrul grupului de lucru.

Considerînd elementele lui  $W(t, \tau)$  ca fiind pagini, se definește dimensiunea grupului de lucru  $\omega(t, \tau)$  ca fiind numărul de pagini în  $W(t, \tau)$ . Presupunînd că dimensiunea grupului de lucru  $\omega(t, \tau)$  este un proces stochastic staționar, rezultă că așteptarea matematică  $\omega(t, \tau)$  este independentă de  $t$  și deci se poate scrie:

$$w(\tau) = \omega(t, \tau)$$

Presupunînd unități de timp discret, Denning și Schwartz (56) dau următoarea expresie pentru dimensiunea medie a grupului de lucru:

$$w(\tau) = \lim_{k \rightarrow \infty} \left[ \frac{1}{k} \sum_{t=1}^{t=k} \omega(t, \tau) \right]$$

A fost arătat în (39,56) că dimensiunea medie a grupului de lucru a unui program este distribuită normal, lucru ce simplifică calculul algebric.

În (52) este arătat că valoarea așteptată a dimensiunii grupului de lucru are următoarele proprietăți:

$$(1) \quad w(\tau) \leq \tau$$

Deoarece numărul maxim de referiri distincte ce pot apărea în  $\tau$  unități de timp virtual este  $\tau$ , avem  $\omega(t, \tau) \leq \tau$  și de aceea  $w(\tau) \leq \tau$

(2)  $w(0) = 0$

Acest lucru este evident, căci nici o pagină nu poate fi referită la timpul zero.

(3)  $w(\tau + \lambda) \geq w(\tau)$  ;  $\lambda \geq 0$

Această proprietate ce arată că  $w(\tau)$  este o funcție nedescrescătoare, rezultă din faptul că în intervale de timp mai lungi pot fi referite un număr mai mare de pagini.

(4)  $w(\tau)$  e convexă.

În fig.25 a fost reprezentată forma curbelor  $w(\tau)$  pentru două tipuri de program.




Fig.25. Dimensiunea așteptată a grupului de lucru.

Programul de tipul 1 are un grup bine definit de pagini favorizate; el are tendința de a-și distribui majoritatea referirilor lui uniform asupra unui grup de  $\tau_0$  pagini favorizate. Pentru intervale  $\tau < \tau_0$  pentru un asemenea program ne putem aștepta ca programul să facă în mod frecvent referiri la pagini distincte noi, iar  $w(\tau)$  să crească aproape linear cu  $\tau$ . Pentru  $\tau \gg \tau_0$  grupul de lucru va conține multe pagini nefolosite. Pentru un program cu o asemenea comportare de acces, alegerea lui  $\tau$  aproape de valoarea  $\tau_0$  nu va afecta eficiența operării, dar va diminua volumul de memorie alocat programului.

Programul de tipul 2 are un grup vag definit de pagini favorizate.

Fie  $x$  o variabilă aleatoare ce caracterizează intervalele de timp virtual între referirile succesive la aceeași



pagină;

Fie:  $F_x(u) = \Pr [x \leq u]$

funcția ei de distribuție și

$$f_x(u) = \frac{dF_x(u)}{du}$$

funcția ei de densitate. În (41) se arată că acest tip de distribuție a intervalelor de interreferiri se poate modela printr-o distribuție hiperexponențială. Fie numărul de referiri la memorie (intervalul de execuție în u.t.v.). Atunci:

$$S(y_i = \tau) = \alpha_i (1 - \alpha_i)^{n-1} \quad i = 1, 2, \dots, n$$

unde:

$S(y_i = \tau)$  = probabilitatea că intervalul de interreferire  
- al paginii  $i$  este egal cu  $\tau$ ;

$\alpha_i$  = probabilitatea de referire a paginii  $i$ ;

$n$  = numărul total de pagini referite de un program.

Probabilitatea unui defect de pagină (sau a unei pagini lipsă)  $\lambda(\alpha)$  este definită ca probabilitatea ca un proces să facă următoarea lui referire la o pagină ce nu este conținută în grupul de lucru  $W(t, \tau)$ . Probabilitatea ca pagina referită să nu fie cuprinsă în  $W(t, \tau)$  este de fapt probabilitatea ca intervalul de interreferire cel mai recent să satisfacă  $x > \tau$ , astfel că:

$$\lambda(\tau) = \Pr [x > \tau] = 1 - F_x(\tau)$$

O pagină  $i$  care este referită numai o dată va avea intervalul ei de interreferire de pagină egal cu infinit.

Dimensiunea grupului de lucru la timpul  $t$  constă din paginile a căror intervale de interreferire sînt mai mici sau egale cu  $\tau$ , o valoare finită; de aceea această determinare a dimensiunii grupului de lucru nu reușește să includă paginile referite o singură dată. De asemenea, modelul de grup de lucru nu consideră efectul variației dimensiunii paginii. Dimensiunile paginilor au un rol definit în determinarea ratelor de paginare și utilizare memoriei.

După cum s-a arătat în cap.2 secțiunea 3.4. strategia de grup de lucru poate fi utilizată ca algoritm de înlocuire și anume: într-un mediu multiprogramat, numai acele programe sînt eligibile de a putea fi rulate, a căror grup de lucru nu depășește spațiul propriu disponibil în memoria principală. A fost

remarcată deficiența legată de utilizarea unui asemenea algoritm și care constă în dificultatea de a măsura dinamic parametrul de grup de lucru, cu scopul de a estima dimensiunea grupului de lucru.

Conceptul de grup de lucru este frecvent utilizat în studiile de alocare a resurselor. Coffman și Ryan (39) au comparat efectul partiționării fixe și dinamice a memoriei, bazată pe cerințele de grup de lucru ale unui program; este presupus că dimensiunea grupului de lucru urmează o distribuție normală. Rodriguez și Dupuy (141) prezintă proiectarea, implementarea și evaluarea unui dispecer pentru grupuri de lucru. Ferrari (67) cercetează posibilitatea îmbunătățirii comportării localizate a programelor prin utilizarea grupurilor de lucru critice. Ghancu (81) propune un algoritm pentru partiția memoriei principale între  $N$  programe competitive, cu caracteristici diferite, algoritm bazat pe o strategie optimă de alocare, obținută prin utilizarea conceptului de grup de lucru. Bryant (28) analizează rezultate empirice a unor dimensiuni ale grupurilor de lucru și ajunge la concluzia că ipoteza privind distribuția normală a dimensiunilor grupurilor de lucru nu este justificată.

### 1.3. Modele stochastice.

Vom descrie câteva modele stochastice, ce se referă la reprezentarea analitică a șirului de referiri de pagină a unui program (vezi cap.2 secțiunea 3.3.1.).

#### 1.3.1. Model cu probabilități constante.

Fiind date cele  $N$  pagini ale unui program, numerotate de la 1 la  $N$ , modelul de comportament cel mai simplu constă în a atașa fiecăreia din aceste pagini o probabilitate de referire  $p_i$ . Evident:


$$\sum_{i=1}^N p_i = 1$$

$p_i$  determină probabilitatea pentru ca pagina  $i$  să facă obiectul celei de a  $k$ -a referiri. Această probabilitate este constantă în timp, deci independentă de  $k$ .

Un asemenea model poate să fie utilizat pentru a reprezenta într-un mod aproximativ fenomenul de scădere a performanței în cazul unei alocări date de memorie; pentru aceasta este suficient să se aleagă un subsansamblu de  $M$  pagini, fiecareia din care i se atribuie o probabilitate  $p$ , restul paginilor primind o probabilitate  $q$

$$Mp + (N - M)q = 1$$

Executând programul într-un mediu cu o anumită alocare de memorie, se obține pentru reprezentarea probabilității unui defect de pagină curba din fig.26, care corespunde suficient de precis rezultatelor raportate în (25).



Probabilitatea unui defect de pagină (în regim staționar)

parachor dimensiunea  
programului

dimensiunea memoriei alocate

Fig.26. Asupra probabilității unui defect de pagină.

Dimensiunea  $L_0$  a memoriei alocate, la care se constată o schimbare clară în modul de variație a curbei corespunde dimensiunii de alocare a memoriei, definite de Belady (19) drept **parachor**: Acesta din urmă reprezintă volumul de informații care trebuie să fie rezident în memoria principală, astfel încât programul să cheltuiască nu mai mult de jumătate din timpul de execuție în așteptări de pagină.

Cele  $L_0$  pagini a căror probabilitate de referire este  $Lp > 0,5$  reprezintă un "nucleu" al programului, al cărui parametru  $\frac{Lp}{1 - pM}$  poate fi pus în legătură cu modul în care programul își distribuie referirile: valori mari ale acestui raport caracterizează un program cu referiri localizate; valori apropiate de unitate corespund unui program ce-și distribuie în mod uniform referirile.

În cadrul acestui model, programul este caracterizat prin două numere fără dimensiune:  $\frac{n_m}{n}$  raportul dintre dimensiunea nucleului și dimensiunea totală a programului și de raportul  $\frac{n_m}{1-p_m}$ .

### 1.3.2. Model markovian staționar.

În cazul acestui model se consideră constante probabilitățile de tranziție  $p_{ij}$  între pagini:

$$p_{ij} = \Pr(r_{k+1} = j \mid r_k = i) \quad i, j \in [1, N]$$

și

$$\sum_{j=1}^N p_{ij} = 1 \quad i \in [1, N]$$

Matricea de tranziție  $p_{ij}$  o notăm cu  $P$ .

Vom arăta câteva proprietăți ale acestui model.

Presupunem că toate paginile programului fac obiectul unei referiri într-un interval de timp suficient și că nu există "stare de absorbție" (adică  $p_{ii} \neq 1$ ). Aceste două condiții se traduc prin ipoteza că lanțul Markov reprezentând comportarea de acces a programului este regulat. Probabilitatea de referire se exprimă prin:

$$\Pr(r_{k+1} = i) = \sum_{j=1}^n p_{ij}^{(k)} b_j$$

unde  $|b_i|$  este vectorul probabilităților inițiale ( $b_i$  = probabilitatea ca prima referire să fie făcută la pagina  $i$ ), iar  $p_{ij}^{(k)}$  reprezintă elementul  $(i, j)$  al matricii  $P^k$ . Comportarea puterilor succesive ale matricii de tranziție joacă un rol determinant în acest model. Asupra acestei comportări s-a arătat că pentru un lanț Markov regulat, puterile succesive  $P^k$  a matricii de tranziție converg spre o matrice limită  $A$ , a cărei linii sînt identice cu un vector  $a$ . Vectorul  $a$  este soluția ecuației.

$$aP = a$$

și este un vector al probabilităților ( $\sum a_i = 1$ ) care condiționează comportarea asimptotică a lanțului Markov, în sensul că:

./.

$$\lim_{k \rightarrow \infty} \Pr(x_k = i) = a_i$$

Utilizarea acestui model este justificată în cazul unor studii precise privind comportarea de acces a programelor sau în cazul unui număr redus de tranziții.

Considerînd referirea la pagini a unui program un proces în puncte, în (111) se propune un model semi-Markov cu două stări ce descrie apariția defectelor de pagină. Modelul este definit pe baza girului de valori  $\{X_j\}$  ce caracterizează intervalele între defectele de pagină. Se presupune că există două tipuri de asemenea intervale, cu funcțiile de densitate probabilistică  $p_1(x)$  și  $p_2(x)$ . Modelul postulează că există un lanț Markov cu două stări, cu matricea de tranziție:

$$P = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix} = \begin{pmatrix} \alpha_1 & 1 - \alpha_1 \\ 1 - \alpha_2 & \alpha_2 \end{pmatrix}$$

astfel încît fiind dat că  $X_{j-1}$  are f.d.p.  $p_1(x)$ , probabilitatea ca  $X_j$  să aibă f.d.p.  $p_2(x)$  este  $1 - \alpha_1$ ; probabilitatea ca  $X_j$  să aibă f.d.p.  $p_1(x)$  este  $\alpha_1$ , independent de tipul sau lungimea intervalelor anterioare.

Pentru f.d.p. a primului tip de intervale se propune distribuția geometrică  $p_1(x)$  avînd media  $\mu_1$ :

$$p_1(x) = p_1^{x-1} (1 - p_1) \quad (0 < p_1 < 1; x = 1, 2, \dots)$$

$$\mu_1 = \frac{1}{1 - p_1}$$

Pentru f.d.p. a celui de al doilea tip de intervale se propune distribuția negativ-binomială:

$$p_2(x, k) = \binom{k + x - 2}{x - 1} p_2^{x-1} (1 - p_2)^k$$

$$(0 < p_2 < 1; k > 0; x = 1, 2, \dots)$$

Modelul impune estimarea unui număr de 6 parametri.

O extensie a acestui model pentru o ierarhie cu 3 nivele este dată în (76).

#### 1.4. Critica modelelor prezentate.

Modelele prezentate nu pot fi folosite ca instrument de cercetare în analiza anomaliei dimensiunii de pagină, căci ele

nu consideră efectul variației dimensiunii de pagină. În plus, mai pot fi semnalate și alte deficiențe ale acestor modele.

Astfel, în cadrul modelului bazat pe funcția de timp de existență:

- parametrii modelului  $k_1$  și  $k_2$  nu sînt în mod clar definiți pe baza proprietăților programului care este modelat;

- modelul este valid pentru programe reale numai pe o porțiune a domeniului de variație a lui  $s$  (alocarea de memorie).

În privința modelului bazat pe grup de lucru se poate constata:

- dificultatea de a măsura dinamic parametrul de grup de lucru (cu scopul de a estima dimensiunea grupului de lucru);

- modul cum este definită dimensiunea grupului de lucru nu permite includerea în această dimensiune a paginilor care sînt referite o singură dată.

În cazul modelelor stochastice, cele ce presupun probabilități constante de referire a paginilor sau probabilități constante de tranziție între pagini impun un grad de simplificare prea mare al comportării de acces a unui program, iar modelele ce utilizează proprietățile unui proces semi-Markov conduc la necesitatea estimării unui număr relativ mare de parametri, care nu pot fi puși în legătură directă cu proprietățile programului modelat.

În această situație, pentru analiza anomaliei dimensiunii de pagină apare necesitatea elaborării unui instrument de cercetare corespunzător, un model al comportării de acces a unui program construit în așa manieră, încît să ia în considerație și efectul variației dimensiunii de pagină, iar parametrii modelului să fie în mod clar definiți pe baza proprietăților programului care este modelat.

## 2. Modelul propus al comportării de acces a programului.

În cele ce urmează vom construi un model analitic, ce presupune următoarea comportare de acces a programului:

- (1) selectarea aleatoare a unei locații "a" în spațiul de adrese virtuale al programului;
- (2) selectarea aleatoare a unui ciclu cu lungimea  $\alpha$ ;
- (3) accesul la  $\alpha$  locații în ciclul (2) de mai sus secvențial de  $\sigma$  ori;
- (4) repetarea pașilor de mai sus.

Un ciclu ce se extinde în afara ultimei adrese virtuale disponibile programului este continuat la începutul spațiului de adrese virtuale. Deci, în conformitate cu cele de mai sus, comportarea de acces a programului constă în apelarea unei serii de cicluri, poziția și dimensiunea cărora se schimbă în mod aleator.

Vom fi interesați de numărul defectelor de pagină generate de un program cu o asemenea comportare de acces.

Fie:

$P$  = dimensiunea programului (în cuvinte sau octeți);

$p$  = dimensiunea paginii;

$p \lceil P/p \rceil$  = dimensiunea aparentă a programului considerată de un sistem cu dimensiunea de pagină  $p$ .

Notația  $\lceil x \rceil$  reprezintă cel mai mic întreg, care este mai mare sau egal cu  $x$ .

### 2.1. Efectele lungimii ciclului de program asupra numărului defectelor de pagină.

Primul lucru pe care îl determinăm este numărul de pagini distincte referite în cadrul accesului la un ciclu. Acest număr este funcție de lungimea ciclului și de poziția ciclului în spațiul de adrese virtuale.

Spațiul de adrese virtuale poate fi reprezentat ca în fig. 27, în care linia A-B descrie un segment al spațiului de adrese virtuale; liniile de diviziune sînt limite de pagini, iar o limită de pagină este presupusă făcînd parte din pagina din partea dreaptă.




Fig.27. Reprezentarea spațiului de adrese virtuale.

Considerăm un ciclu cu lungimea  $\alpha$  ce începe la o adresă limită de pagină. Numărul de pagini distincte referite în cadrul

ciclului este  $\left\lceil \frac{\alpha}{p} \right\rceil$ . Din fig.27 rezultă că, mutînd poziția ciclului spre dreapta, numărul de pagini distincte referite va rămîne  $\left\lceil \frac{\alpha}{p} \right\rceil$  pînă în momentul în care capătul din dreapta al ciclului traversează o limită de pagină. În acel moment numărul de pagini referite va deveni  $\left\lceil \frac{\alpha}{p} \right\rceil + 1$  și rămîne la această valoare pînă în momentul în care capătul din stînga al ciclului traversează o limită de pagină. Astfel, numărul de pagini distincte referite de un ciclu cu lungimea  $\alpha$  va fi  $\left\lceil \frac{\alpha}{p} \right\rceil$  sau  $\left\lceil \frac{\alpha}{p} \right\rceil + 1$  în funcție de poziția ciclului în spațiul adreselor virtuale.

Vrem să determinăm pozițiile ciclului ce conduc la referirea a  $\left\lceil \frac{\alpha}{p} \right\rceil$  și respectiv  $\left\lceil \frac{\alpha}{p} \right\rceil + 1$  pagini distincte. Considerăm poziția ciclului în spațiul adreselor virtuale determinată de adresa de început a ciclului sau marginea din stînga pe fig.28. Vom arăta că, în cazul poziționării adresei de început a ciclului la oricare din primele

$\left\lceil \frac{\alpha}{p} \right\rceil \cdot p - \alpha$  adrese, vor fi referite în ciclu un număr de  $\left\lceil \frac{\alpha}{p} \right\rceil$  pagini distincte.




Fig.28. Poziția ciclului în spațiul de adrese virtuale.

Dimensiunea aparentă a ciclului, considerată de sistem, este de  $\left\lceil \frac{\alpha}{p} \right\rceil \cdot p$  cuvinte: în cadrul acestei dimensiuni rămîn neutilizate, în execuția ciclului, un număr de  $\left\lceil \frac{\alpha}{p} \right\rceil \cdot p - \alpha$  adrese. Astfel se poate poziționa ciclul la oricare din primele  $\left\lceil \frac{\alpha}{p} \right\rceil \cdot p - \alpha$  adrese a oricărei pagini și se vor referi numai  $\left\lceil \frac{\alpha}{p} \right\rceil$  pagini distincte. Corespunzător, dacă ciclul este poziționat la oricare din  $p - (\left\lceil \frac{\alpha}{p} \right\rceil \cdot p - \alpha)$  sau

./.



$p - \left\lfloor \frac{\alpha}{p} \right\rfloor \cdot p + \alpha$  adrese a oricărui pagini, ciclul va referi un număr de  $\left\lfloor \frac{\alpha}{p} \right\rfloor + 1$  pagini distincte.

Considerăm poziția "a" a fiecărui ciclu ca fiind o variabilă aleatoare uniform distribuită, al cărui domeniu este întreg spațiul de adrese virtuale al sistemului. Astfel, pentru probabilitățile de referire de către un ciclu a unui număr de pagini  $N$  distincte avem următoarele expresii:

$$\text{Pr (referire } \left\lfloor \frac{\alpha}{p} \right\rfloor \text{ pagini distincte)} = \left\lfloor \frac{\alpha}{p} \right\rfloor - \frac{\alpha}{p} ; \quad (1)$$

$$\text{Pr (referire } \left\lfloor \frac{\alpha}{p} \right\rfloor + 1 \text{ pagini distincte)} = 1 - \left\lfloor \frac{\alpha}{p} \right\rfloor + \frac{\alpha}{p} \quad (2)$$

## 2.2. Considerații preliminare privind numărul de defecte de pagină.

Sîntem interesați de numărul de defecte de pagină generate în decursul accesului la un asemenea ciclu. Există doi factori importanți ce trebuie considerați. Primul trebuie determinat dacă numărul de pagini distincte referite de ciclu este mai mare decît spațiul alocat  $\frac{S}{p}$ . Dacă avem o asemenea situație, vom avea de-a face cu o paginare aproape continuă. Această activitate va fi consecința faptului că, în timpul accesului secvențial la un asemenea ciclu, paginile ce compun ciclul vor trebui înlocuite din memoria principală înainte de a se completa ciclul și a fi referite din nou. În termenii modelului de grup de lucru, într-un asemenea caz se constată că grupul de lucru al ciclului este mai mare decît spațiul alocat.

În cazul în care spațiul alocat  $\frac{S}{p}$  este mai mare decît sau egal cu numărul de pagini unice referite de ciclu, vom constata o activitate intensă de paginare pe timpul cît paginile ce compun ciclul sînt aduse în memoria principală, urmată de o perioadă de execuție, neîntreruptă de defecte de pagină suplimentare.

Al doilea factor ce trebuie avut în vedere este acela al probabilității de a găsi deja aduse în memoria principală (sau alt echivalent similar în ierarhie) paginile necesitate pentru execuția ciclului, ca rezultat al activității de paginare ce a avut loc mai devreme. Aceasta înseamnă că, în momentul în care începem fiecare procedură nouă de acces la un

nou ciclu, există probabilitatea de a găsi unele pagini necesitate de ciclu deja rezidente în memoria principală.

Pentru a determina numărul de defecte de pagină DP ce apar în timpul accesului la un nou ciclu cu lungimea de  $\alpha$  cuvinte de  $\sigma$  ori va fi necesar să considerăm două cazuri distincte:

$DP(\alpha) = DP_1(\alpha)$  pentru cazul în care adresa  $a$  de început a ciclului este situată la primele  $\left\lfloor \frac{\alpha}{p} \right\rfloor \cdot p - \alpha$  adrese ale unei pagini; (3)

$= DP_2(\alpha)$  pentru cazul în care adresa  $a$  de început a ciclului este situată în ultimile  $p - \left\lfloor \frac{\alpha}{p} \right\rfloor \cdot p + \alpha$  adrese ale unei pagini; (4)

Necesitatea celor două cazuri este determinată de numărul diferit de pagini distincte referite în fiecare caz și anume, în primul caz sînt referite  $\left\lfloor \frac{\alpha}{p} \right\rfloor$  pagini distincte, iar în al doilea caz sînt referite  $\left\lfloor \frac{\alpha}{p} \right\rfloor + 1$  pagini distincte.

Expresia pentru  $DP_2(\alpha)$  va putea fi obținută din expresia pentru  $DP_1(\alpha)$ , ținînd seama de această diferență privind numărul paginilor distincte referite.

În ceea ce privește  $DP_1(\alpha)$  putem constata că ea însăși se poate găsi în două situații și anume:

$$DP_1(\alpha) = DP_{1a}(\alpha) \quad \text{pentru} \quad \left\lfloor \frac{\alpha}{p} \right\rfloor \leq \frac{\sigma}{p}; \quad (5)$$

$$= DP_{1b}(\alpha) \quad \text{pentru} \quad \left\lfloor \frac{\alpha}{p} \right\rfloor > \frac{\sigma}{p}; \quad (6)$$

În cazul (1a) numărul de pagini distincte referite este mai mic sau egal cu numărul de pagini alocate în memorie. Astfel, după referirea inițială a tuturor paginilor ce alcătuiesc ciclul, nu vom mai avea nici o altă activitate de paginare. Este evident că vor exista, cel mult  $\left\lfloor \frac{\alpha}{p} \right\rfloor$  defecte de pagină în decursul accesului la acest ciclu, căci după ce a avut loc primul acces la acest ciclu, toate paginile cerute se vor găsi în memorie și următoarele accese la acest ciclu nu vor produce alte defecte de pagină.

În cazul (1b), în cadrul ciclului sînt referite mai multe pagini distincte decît spațiul alocat în memorie. În această situație, presupunînd LRU, FIFO sau alt algoritm similar de înlocuire a paginilor (vezi cap.2 secțiunea 3.4),

vom constata că după referirea primelor  $\frac{s}{p}$  pagini distincte din cadrul ciclului, va apărea un defect de pagină de fiecare dată ce secvența referirilor traversează o limită de pagină. Aceasta va continua atâta timp cât are loc accesul la ciclu. Deoarece accesul la acest ciclu va avea loc de  $\sigma$  ori, vor apărea un număr maxim de  $\left\lceil \frac{\sigma}{p} \right\rceil \cdot \sigma$  defecte de pagină.

### 2.3. Efectele paginării anterioare.

Un alt factor ce trebuie considerat este acela al găsirii în memorie a uneia sau a mai multor din paginile necesitate  $\left\lceil \frac{\sigma}{p} \right\rceil$  distincte. Când începe accesul la ciclul considerat în memorie se găsesc  $\frac{s}{p}$  pagini, ca rezultat al execuției unuia sau mai multor cicluri de acces precedente. Există posibilitatea ca între aceste pagini să se afle și unele din cele necesitate de noul ciclu și ca atare pot rămâne în memorie (să nu fie înlocuite).

Este evident că numărul defectelor de pagină evitate în acest mod este o variabilă aleatoare. Se poate de asemenea presupune că media și funcția de densitate a acestei variabile aleatoare sînt funcții de toți  $a$  și  $\alpha$  precedenți. Vom evita aceste complicații, făcînd cîteva ipoteze și înlocuind această variabilă aleatoare cu media ei. Astfel, aproximăm probabilitatea ca pagina  $i$  a unui ciclu curent să se afle deja dispusă în memorie, prin expresia:

$$\text{Pr (pagina } i \text{ în memorie)} = \frac{\frac{s}{p} - i + 1}{\left\lceil \frac{p}{p} \right\rceil} \text{ pentru } s < p \cdot \left\lceil \frac{p}{p} \right\rceil \quad (7)$$

$$= 1 \quad \text{pentru } s \geq p \cdot \left\lceil \frac{p}{p} \right\rceil \quad (8)$$

Sînt cîteva motive pentru care această aproximație poate fi considerată corespunzătoare. În primul rînd, ea este suficient de precisă pentru valori mici ale lui  $i$ , iar aceste valori mici ale lui  $i$  se întîlnesc mai frecvent. Valoarea lui  $i$  nu poate depăși  $\frac{s}{p}$  sau  $\left\lceil \frac{\sigma}{p} \right\rceil + 1$ . Aceasta înseamnă că, pentru a putea implica valori mari ale lui  $i$ , trebuie să avem o alocare  $s$  mare și o lungime de ciclu  $\alpha$  mare. În al doilea rînd, vom utiliza o însumare a acestor probabilități pentru  $i = 1$  pînă la  $i = \left\lceil \frac{\sigma}{p} \right\rceil$  sau în unele cazuri  $i = \left\lceil \frac{\sigma}{p} \right\rceil + 1$ . Valorile acestor termeni în relația de aproximare propusă scad cu creșterea lui  $i$ . Astfel, termenii dominanți în serie sînt acci cu  $i$  mici, pentru care apro-

aproximația este mai precisă.

Putem scrie valoarea așteptată a numărului acestor pagini, ce se găsesc deja în memorie, pentru fiecare nou ciclu, sub următoarea formă:

$$\sum_{i=1}^k \frac{\frac{s}{p} - i + 1}{\left\lfloor \frac{p}{p} \right\rfloor} = \frac{k \left( \frac{s}{p} + 1 \right) - \sum_{i=1}^k i}{\left\lfloor \frac{p}{p} \right\rfloor} = \frac{k \cdot \frac{s}{p} + k - \frac{k(k+1)}{2}}{\left\lfloor \frac{p}{p} \right\rfloor}$$

pentru  $s < p \left\lfloor \frac{p}{p} \right\rfloor$  (9)

și

$$\sum_{i=1}^k 1 = k \quad \text{pentru } s \geq p \left\lfloor \frac{p}{p} \right\rfloor \quad (10)$$

unde:

$$k = \left\lfloor \frac{\alpha}{p} \right\rfloor \quad \text{în cazul la}$$

și

$$k = \frac{s}{p} \quad \text{în cazul lb}$$

Valorile lui  $k$  provin din următoarele considerații:

În cazul (la) numărul de pagini referite este mai mic sau egal cu numărul alocat de pagini. În acest caz trebuie să terminăm sumarea la numărul de pagini distincte referite, care este  $\left\lfloor \frac{\alpha}{p} \right\rfloor$ . În cazul (lb) numărul de pagini distincte referite este mai mare decât numărul alocat de pagini. Numărul alocat de pagini este  $\frac{s}{p}$  și ne putem aștepta să găsim pagini, ca rezultat al paginării anterioare, numai în timpul referirii primelor  $\frac{s}{p}$  pagini distincte.

Făcând înlocuirile, se obțin următoarele expresii:

Cazul la.

$$\left\lfloor \frac{\alpha}{p} \right\rfloor \leq \frac{s}{p} \quad \text{și} \quad k = \left\lfloor \frac{\alpha}{p} \right\rfloor$$

subcazul  $s < p \left\lfloor \frac{p}{p} \right\rfloor$

$$\sum_{i=1}^{\left\lfloor \frac{\alpha}{p} \right\rfloor} \frac{\frac{s}{p} - i + 1}{\left\lfloor \frac{p}{p} \right\rfloor} = \frac{\left\lfloor \frac{\alpha}{p} \right\rfloor \cdot \frac{s}{p} - \left\lfloor \frac{\alpha}{p} \right\rfloor - \frac{1}{2} \cdot \left\lfloor \frac{\alpha}{p} \right\rfloor^2 - \frac{1}{2} \left\lfloor \frac{\alpha}{p} \right\rfloor}{\left\lfloor \frac{p}{p} \right\rfloor} = \frac{\left\lfloor \frac{\alpha}{p} \right\rfloor \left( \frac{s}{p} - \frac{1}{2} \left\lfloor \frac{\alpha}{p} \right\rfloor \right) - \frac{1}{2} \left\lfloor \frac{\alpha}{p} \right\rfloor}{\left\lfloor \frac{p}{p} \right\rfloor} \quad (11)$$

./.

Subcazul  $s \geq p \left\lceil \frac{P}{p} \right\rceil$

$$\sum_{i=1}^{\left\lceil \frac{R}{p} \right\rceil} 1 = \left\lceil \frac{R}{p} \right\rceil \quad (12)$$

Cazul 1 b.

$$\left\lceil \frac{R}{p} \right\rceil > \frac{s}{p}$$

Ținând seama și de relația evidentă:

$$\left\lceil \frac{R}{p} \right\rceil < \left\lceil \frac{P}{p} \right\rceil$$

rezultă că:

$$s < p \cdot \left\lceil \frac{R}{p} \right\rceil \leq p \cdot \left\lceil \frac{P}{p} \right\rceil$$

Deci, în cazul 1 b nu sînt posibile două subcazuri, ci doar unul singur:

$$s < p \cdot \left\lceil \frac{P}{p} \right\rceil$$

$$\sum_{i=1}^{\frac{s}{p}} \frac{\frac{s}{p} - i + 1}{\left\lceil \frac{P}{p} \right\rceil} = \frac{\frac{s}{p} \left( \frac{s}{p} + 1 \right) - \frac{1}{2} \left( \frac{s}{p} + 1 \right)}{\left\lceil \frac{P}{p} \right\rceil} = \frac{1}{2 \left\lceil \frac{P}{p} \right\rceil} \left( \frac{s^2}{p^2} + \frac{s}{p} \right) \quad (13)$$

Scăzînd numărul mediu al paginilor ce se găsesc deja în memorie din numărul defectelor posibile de pagină, se obține valoarea reală a numărului defectelor de pagină.

Cazul 1 a.

Subcazul:  $s < p \left\lceil \frac{P}{p} \right\rceil$

$$\begin{aligned} DP_{1a} &= \left\lceil \frac{R}{p} \right\rceil - \frac{\left\lceil \frac{R}{p} \right\rceil \left( \frac{s}{p} - \frac{1}{2} \left\lceil \frac{R}{p} \right\rceil \right) + \frac{1}{2} \left\lceil \frac{R}{p} \right\rceil}{\left\lceil \frac{P}{p} \right\rceil} = \\ &= \left\lceil \frac{R}{p} \right\rceil \left( 1 - \frac{s}{2 \left\lceil \frac{P}{p} \right\rceil} - \frac{1}{2 \left\lceil \frac{P}{p} \right\rceil} + \frac{1}{2 \left\lceil \frac{P}{p} \right\rceil} \cdot \left\lceil \frac{R}{p} \right\rceil \right) \quad (14) \end{aligned}$$

Subcazul:  $s \geq p \left\lceil \frac{P}{p} \right\rceil$

$$DP_{1a} = \left\lceil \frac{R}{p} \right\rceil - \left\lceil \frac{R}{p} \right\rceil = 0 \quad (15)$$

./.

Cazul 1 b.

$$DP_{1b} = \left\lfloor \frac{\alpha}{p} \right\rfloor - \frac{1}{2 \left\lfloor \frac{p}{p} \right\rfloor} \left( \frac{s^2}{p} + \frac{s}{p} \right) \quad (16)$$

Expresiile pentru  $DP_{2a}$  și  $DP_{2b}$  se obțin direct din expresiile  $DP_{1a}$  și  $DP_{1b}$  prin înlocuirea lui  $\left\lfloor \frac{\alpha}{p} \right\rfloor$  prin  $\left\lfloor \frac{\alpha}{p} \right\rfloor + 1$

Astfel se obține:

$$DP_{2a} = \left( \left\lfloor \frac{\alpha}{p} \right\rfloor + 1 \right) \left[ 1 - \frac{s}{p \left\lfloor \frac{p}{p} \right\rfloor} - \frac{1}{2 \left\lfloor \frac{p}{p} \right\rfloor} + \frac{1}{2 \left\lfloor \frac{p}{p} \right\rfloor} \left( \left\lfloor \frac{\alpha}{p} \right\rfloor + 1 \right) \right] \quad (17)$$

$$\text{pentru } \left\lfloor \frac{\alpha}{p} \right\rfloor + 1 \leq \frac{s}{p} \quad \text{și} \quad s < p \left\lfloor \frac{p}{p} \right\rfloor$$

$$DP_{2b} = \left( \left\lfloor \frac{\alpha}{p} \right\rfloor + 1 \right) \left[ 1 - \frac{1}{2 \left\lfloor \frac{p}{p} \right\rfloor} \left( \frac{s^2}{p} + \frac{s}{p} \right) \right] \quad (18)$$

$$\text{pentru } \left\lfloor \frac{\alpha}{p} \right\rfloor + 1 > \frac{s}{p}$$

#### 2.4. Considerarea repartiției lunginii ciclurilor.

Pentru a calcula valoarea medie a defectelor de pagină trebuie cunoscută funcția de densitate de repartiție pentru  $\alpha$ , lungimea unui ciclu.

Se poate considera că un program real s-ar putea modela printr-un număr de cicluri de lungimi fixe la care s-ar adăuga câteva cicluri de lungimi variabile. Un ciclu de lungime fixă este format de exemplu în cazul unui ciclu DO real. Ciclurile de lungimi variabile sînt generate în cadrul unor activități, precum căutarea într-o listă a unei anumite valori. Aceste considerații ar conduce la o funcție de densitate, conținînd un număr de "vîrfuri". Nu urmărim însă în cadrul acestui model realizarea unei descrieri atît de detaliate a programului.

Putem considera însă o funcție de densitate de repartiție cu un singur maximum dominant, cu parametri corespunzători, care permit controlul asupra alurii curbei și poziției maximum-ului. O asemenea flexibilitate privind controlul asupra alurii curbei și poziției maximum-ului este oferită de utilizarea repartiției de tip  $\Gamma$ . Parametrii aces-

teii repartiții trebuie aleși astfel încât concordanța cu repartiția reală a lungimii ciclurilor să fie satisfăcătoare, îndeosebi pe intervalul ce prezintă interes  $[1, P]$ .

Pentru funcția de repartiție de tip  $\Gamma$  densitatea de repartiție este determinată prin:

$$f(u) = \begin{cases} \frac{\xi^\beta}{\Gamma(\beta)} u^{\beta-1} e^{-\xi u} & \text{dacă } u > 0 ; \\ 0 & \text{dacă } u \leq 0 ; \end{cases} \quad \xi > 0; \quad \beta > 0$$

unde:  $\Gamma(\beta)$  este funcția  $\Gamma$  definită ca

$$\Gamma(\beta) = \int_0^\infty x^{\beta-1} e^{-x} dx$$

iar  $\Gamma(\beta + 1) = \beta \Gamma(\beta)$  pentru orice  $\beta$ .

O curbă ce indică modul de variație al funcției de densitate pentru repartiția de tipul  $\Gamma$  avînd parametrul  $\beta > 1$  este reprezentată în fig.29.




Fig.29. Funcția de densitate pentru repartiția de tipul  $\Gamma$  avînd  $\beta > 1$

Cei doi parametri  $\xi$  și  $\beta$  ai repartiției de tip  $\Gamma$  îi vom determina, egalînd valorile medii și dispersiile funcțiilor de repartiție reală ( $r$ ) și aproximantă ( $a$ ), considerate pe intervalul  $[0, P]$ .

Astfel:

$$M_r[u] = M_a[u] = \int_0^P u f(u) du \quad (19)$$

$$M_r[u^2] = M_a[u^2] = \int_0^P u^2 f(u) du \quad (20)$$

$$D_r^2[u] = D_a^2[u] = M_r[u^2] - M_r^2[u] = M_a[u^2] - M_a^2[u] \quad (21)$$

Pe baza valorilor reale ale lungimilor ciclurilor programului modelat, valorile pentru  $M_r[u]$  și  $M_r[u^2]$  pot fi determinate numeric. Pe de altă parte, pentru repartiția aproximantă de tipul  $\Gamma$  valorile  $M_a[u]$  și  $M_a[u^2]$  pot fi exprimate ca funcții de parametri  $\xi$  și  $\beta$

$$M_r[u] = \int_0^P u \cdot \frac{1}{\Gamma(\beta)} \xi^\beta u^{\beta-1} e^{-\xi u} du = \frac{1}{\xi \Gamma(\beta)} \int_0^{\xi P} (\xi u)^\beta e^{-\xi u} d(\xi u) =$$

$$= \frac{1}{\xi \Gamma(\beta)} \int_0^{\xi P} v^\beta e^{-v} dv = \frac{\beta}{\xi} \frac{1}{\Gamma(\beta+1)} \int_0^{\xi P} v^{(\beta+1)-1} e^{-v} dv =$$

$$= \frac{\beta}{\xi} I[\xi P; \beta+1] \quad (22)$$

$$M_a[u^2] = \int_0^P u^2 \cdot \frac{1}{\Gamma(\beta)} \xi^\beta u^{\beta-1} e^{-\xi u} du = \frac{1}{\xi^2 \Gamma(\beta)} \int_0^{\xi P} v^{(\beta+2)-1} e^{-v} dv =$$

$$= \frac{(\beta+1)\beta}{\xi^2 \Gamma(\beta+2)} \int_0^{\xi P} v^{(\beta+2)-1} e^{-v} dv = \frac{(\beta+1)\beta}{\xi^2} I[\xi P, \beta+2] \quad (23)$$

unde:

$$I(x, z) = \frac{1}{\Gamma(z)} \int_0^x u^{z-1} e^{-u} du$$

este funcția  $\Gamma$  incompletă, tabulată.

Dacă valoarea  $P$  este suficient de mare, atunci  $I[\xi P; \beta+1]$  și  $I[\xi P; \beta+2]$  pot fi considerate egale cu unitatea. Atunci se poate considera că:

$$M_a[u] \approx \frac{\beta}{\xi} \quad (24)$$

$$M_a[u^2] \approx \frac{\beta(\beta+1)}{\xi^2} \quad (25)$$

$$D_a^2[u] \approx \frac{\beta}{\xi^2} \quad (26)$$

De aici se obțin următoarele estimări pentru  $\xi$  și  $\beta$ :

$$\xi = \frac{M_a[u]}{D_a^2[u]} = \frac{M_r[u]}{D_r^2[u]} \quad (27)$$

și

$$\beta = \xi M_a[u] = \frac{M_a^2[u]}{D_a^2[u]} = \frac{M_r^2[u]}{D_r^2[u]} \quad (28)$$



În final, repartiția de tipul  $\Gamma$  avînd parametrii  $\xi$  și  $\beta$  determinați conform relațiilor (27) și (28) este utilizată pentru aproximarea repartiției lungimii ciclurilor programului în intervalul  $[1, P]$ .

### 2.5. Elaborarea modelului final.

Valoarea medie a numărului de defecte de pagină DP ( $\alpha$ ) poate fi exprimată ca:

$$M[DP(\alpha)] = \int_0^P \left[ DP_1(\alpha) P(\text{Caz } 1|\alpha) \cdot f(\alpha) + DP_2(\alpha) P(\text{Caz } 2|\alpha) \cdot f(\alpha) \right] d\alpha \quad (29)$$

Pentru a ține seama de schimbările ce apar în reprezentarea funcțiilor  $DP_1(\alpha)$  și  $DP_2(\alpha)$  la punctele  $\alpha = s - p$  și  $\alpha = s$  este necesară împărțirea integralei (29) în trei integrale separate.

$$\begin{aligned} M[DP(\alpha)] = & \int_0^{s-p} \left[ DP_{1a}(\alpha) P(\text{Caz } 1|\alpha) \cdot f(\alpha) + DP_{2a}(\alpha) P(\text{Caz } 2|\alpha) \cdot f(\alpha) \right] d\alpha \\ & + \int_{s-p}^s \left[ DP_{1a}(\alpha) P(\text{Caz } 1|\alpha) \cdot f(\alpha) + DP_{2b}(\alpha) P(\text{Caz } 2|\alpha) \cdot f(\alpha) \right] d\alpha \\ & + \int_s^P \left[ DP_{1b}(\alpha) P(\text{Caz } 1|\alpha) \cdot f(\alpha) + DP_{2b}(\alpha) P(\text{Caz } 2|\alpha) \cdot f(\alpha) \right] d\alpha \end{aligned} \quad (30)$$

Probabilitățile  $P(\text{Caz } 1|\alpha)$  și  $P(\text{Caz } 2|\alpha)$  pot fi luate din (1) și (2). Astfel:

$$P(\text{Caz } 1|\alpha) = \left[ \frac{\alpha}{p} \right] - \frac{\alpha}{p}; \quad (31)$$

$$P(\text{Caz } 2|\alpha) = 1 - \left[ \frac{\alpha}{p} \right] + \frac{\alpha}{p} \quad (32)$$

Examinăm în continuare cele trei integrale.


În prima integrală dăm factor comun  $f(\alpha)$ , obținînd:

$$I_1 = \int_0^{s-p} \left[ DP_{1a}(\alpha) P(\text{Caz } 1|\alpha) + DP_{2a}(\alpha) P(\text{Caz } 2|\alpha) \right] f(\alpha) d\alpha \quad (33)$$

$DP_{1a}$  este definită prin:

$$DP_{1a}(\alpha) = \left[ \frac{\alpha}{p} \right] \left( 1 - \frac{s}{p \left[ \frac{1}{p} \right]} - \frac{1}{2 \left[ \frac{1}{p} \right]} + \frac{1}{2 \left[ \frac{1}{p} \right]} \cdot \left[ \frac{\alpha}{p} \right] \right) \quad (34)$$

./.



Se poate observa că între valorile lui  $\alpha$  în care  $\left[ \frac{\alpha}{p} \right]$  se schimbă brusc, funcția  $DP_{1a}(\alpha)$  are valori constante, deci reprezentarea grafică a acestei funcții constă într-o serie de segmente paralele cu axa  $\alpha$ , iar punctele de discontinuitate (aflate la valori ale lui  $\alpha$  ce sînt multiplii întregi de  $p$ ) sînt situate pe curba:

$$F_{11}(\alpha) = \frac{\alpha}{p} \left[ 1 - \frac{s}{p \left[ \frac{\alpha}{p} \right]} - \frac{1}{2 \left[ \frac{\alpha}{p} \right]} + \frac{1}{2 \left[ \frac{\alpha}{p} \right]} \cdot \frac{\alpha}{p} \right]$$

Forma lui  $DP_{2a}(\alpha)$  este aceeași cu a funcției  $DP_{1a}(\alpha)$ , cu excepția faptului că  $\left[ \frac{\alpha}{p} \right]$  este înlocuit cu  $\left[ \frac{\alpha}{p} \right] + 1$ . Deci considerațiile privind reprezentarea funcției  $DP_{1a}(\alpha)$  sînt aplicabile și pentru  $DP_{2a}(\alpha)$ , punctele de discontinuitate fiind situate pe curba:

$$F_{12}(\alpha) = \left( \frac{\alpha}{p} + 1 \right) \left[ 1 - \frac{s}{p \left[ \frac{\alpha}{p} \right]} - \frac{1}{2 \left[ \frac{\alpha}{p} \right]} + \frac{1}{2 \left[ \frac{\alpha}{p} \right]} \left( \frac{\alpha}{p} + 1 \right) \right]$$

În fig.30 sînt reprezentate grafic funcțiile:

$$DP_{1a}(\alpha) \qquad \text{și} \qquad DP_{2a}(\alpha)$$

Vom examina expresia:

$$DP_{1a}(\alpha) P(\text{Caz } 1 | \alpha) + DP_{2a}(\alpha) P(\text{Caz } 2 | \alpha) \qquad (35)$$

pe un domeniu de variație a lui  $\alpha$  cuprins între  $np$  și  $(n+1)p$ .

În fig.31 sînt trasate 3 curbe: în primă  $DP_{1a}(\alpha)$  și  $DP_{2a}(\alpha)$ , iar în următoarele două  $P(\text{Caz } 1 | \alpha)$  și  $P(\text{Caz } 2 | \alpha)$ .




Fig.30. Reprezentarea grafică a funcțiilor  $DP_{1a}(\alpha)$  și  $DP_{2a}(\alpha)$ .




Fig.31. Relativ la analiza expresiei (35).

Valoarea expresiei (35) începe la stînga cu valoarea lui  $DP_{1a}(\alpha)$  și progresează între cele două funcții  $DP_{1a}(\alpha)$  și  $DP_{2a}(\alpha)$ , egalînd pe  $DP_{2a}(\alpha)$  la limita din dreapta a intervalului considerat. Este evident că expresia nu este niciodată mai mare ca  $DP_{2a}(\alpha)$  sau mai mică decît  $DP_{1a}(\alpha)$ .

Inlocuim (35) cu funcția:

$$H_1(\alpha) = \frac{\alpha}{p} \left[ 1 - \frac{s}{\sqrt{\frac{p}{p}}} - \frac{1}{2\left|\frac{p}{p}\right|} + \frac{1}{2\left|\frac{p}{p}\right|} \cdot \frac{\alpha}{p} \right] \quad (36)$$

$H_1(\alpha)$  reprezintă  $DP_{1a}(\alpha)$ , în care  $\left[ \frac{\alpha}{p} \right]$  a fost înlocuit prin  $\frac{\alpha}{p}$ . Se observă că valorile acestei funcții sînt egale cu cele ale funcțiilor  $DP_{1a}(\alpha)$  și  $DP_{2a}(\alpha)$  pentru valori ale lui  $\alpha$  multiplii întregi de dimensiunea paginii (limite de pagină).  $H_1(\alpha)$  este o funcție nedescrescătoare, care satisface

$$DP_{1a}(\alpha) \leq H_1(\alpha) \leq DP_{2a}(\alpha)$$

Deoarece noi sîntem interesați în continuare de integrarea produsului  $H_1(\alpha)$ .  $f(\alpha)$  este clar că erorile introduse prin folosirea funcției  $H_1(\alpha)$  ca aproximație pentru expresia (35) sînt triviale cînd sînt comparate cu alegerea destul de arbitrară a funcției  $f(\alpha)$ .

Examinînd celelalte două integrale din relația (30) se observă că situația, în cadrul fiecăreia, este aproximativ similară. În fiecare avem două funcții care sînt linii drepte între limitele de pagină și cu discontinuități la limitele de pagină.

Fig.32 reprezintă forma generală a funcțiilor  $DP_{1a}(\alpha)$ ,  $DP_{2a}(\alpha)$ ,  $DP_{1b}(\alpha)$  și  $DP_{2b}(\alpha)$ .




Fig.32. Obținerea funcțiilor  $H_1(\alpha)$ .

În integrala a treia din relația (30) înlocuim termenul  $[DP_{1b}(\alpha) P(\text{Caz 1}|\alpha) + DP_{2b}(\alpha) P(\text{Caz 2}|\alpha)]$  (37)

cu:

$$H_3(\alpha) = \frac{\alpha}{p} \sigma - \frac{1}{2 \left| \frac{p}{p} \right|} \left( \frac{s^2}{p^2} + \frac{s}{p} \right) \quad (38)$$

Funcția  $H_3(\alpha)$  poate fi recunoscută ca  $DP_{1b}(\alpha)$ , unde  $\left| \frac{\alpha}{p} \right|$  a fost înlocuit cu  $\frac{\alpha}{p}$ . Din nou putem arăta că  $H_3(\alpha)$  este egală cu expresia (37) în discuție, la limitele de pagină și satisface:

$$DP_{1b}(\alpha) \leq H_3(\alpha) \leq DP_{2b}(\alpha)$$

./.

În integrala a doua din relația (30) analizăm termenul:

$$DP_{1a}(\alpha) P(\text{Cas 1}|\alpha) + DP_{2b}(\alpha) P(\text{Cas 2}|\alpha) \quad (39)$$

Acest termen combină ambele cazuri a și b ilustrate în fig. 32 în domeniul  $\alpha$  cuprins între  $s - p$  și  $s$ . Vom înlocui acest termen cu o linie dreaptă ce unește valorile termenului la limitele de pagină. Forma generală a acestei aproximații este:

$$H_2(\alpha) = (\text{panta}) \cdot \alpha + (\text{const}) \quad (40)$$

Deoarece valorile funcțiilor  $H_1(\alpha)$  și  $H_3(\alpha)$  sînt cunoscute la limitele de pagină, putem calcula panta:

$$\text{panta} = \frac{H_3(s) - H_1(s-p)}{s - (s-p)} = \frac{H_3(s) - H_1(s-p)}{p} \quad (41)$$

iar constanta se determină prin:

$$\text{constanta} = H_3(s) - (\text{panta}) \times s \quad (41 a)$$

Înlocuind în (41) valorile pentru  $H_3(s)$  și  $H_1(s-p)$  determinate conform (38) și (36), se obține:

$$\text{panta} = \frac{1}{p} \left\{ \frac{s}{p} \sigma - \frac{1}{2 \left| \frac{p}{p} \right|} \left( \frac{s^2}{p^2} + \frac{s}{p} \right) - \frac{s-p}{p} \left[ 1 - \frac{s}{p \left| \frac{p}{p} \right|} - \frac{1}{2 \left| \frac{p}{p} \right|} + \frac{1}{\left| \frac{p}{p} \right|} \cdot \frac{s-p}{p} \right] \right\}$$

Efectuînd:

$$\text{panta} = \frac{s}{p^2} (\sigma - 1) + \frac{1}{p} \left( 1 - \frac{1}{\left| \frac{p}{p} \right|} \right) \quad (42)$$

Pentru constantă se obține:

$$\text{constanta} = \frac{s}{p} \sigma - \frac{1}{2 \left| \frac{p}{p} \right|} \left( \frac{s^2}{p^2} + \frac{s}{p} \right) - \frac{s-p}{p^2} (\sigma - 1) - \frac{s}{p} \left( 1 - \frac{1}{\left| \frac{p}{p} \right|} \right)$$

sau:

$$\text{constanta} = \left( \sigma - 1 + \frac{1}{2 \left| \frac{p}{p} \right|} \right) \left( -\frac{s^2}{p^2} + \frac{s}{p} \right) \quad (43)$$

Avînd valorile (42) și (43) pentru pantă și constantă, forma relației (40) de aproximarea funcției  $H_2(\alpha)$  devine:

$$H_2(\alpha) = \left[ \frac{s}{p^2} (\sigma - 1) + \frac{1}{p} \left( 1 - \frac{1}{\left| \frac{p}{p} \right|} \right) \right] \alpha + \left( \sigma - 1 + \frac{1}{2 \left| \frac{p}{p} \right|} \right) \left( -\frac{s^2}{p^2} + \frac{s}{p} \right) \quad (44)$$

Utilizînd funcțiile de aproximare  $H_1(\alpha)$  (36), (44) și (38) valoarea medie (30) a numărului de defecte de pagină se

poate scrie:

$$M[DP(\alpha)] = \int_{s-p}^{s-1} H_1(\alpha) f(\alpha) d\alpha + \int_{s-p}^s H_2(\alpha) f(\alpha) d\alpha + \int_s^{s+\frac{p}{F}} H_3(\alpha) f(\alpha) d\alpha \quad (45)$$

Funcțiile  $H_1(\alpha)$  sînt de forma:

$$H_1(\alpha): a\alpha^2 + b\alpha$$

$$H_2(\alpha): c\alpha + d \quad (46)$$

$$H_3(\alpha): e\alpha + f$$

În relație (45) intervin deci următoarele 3 tipuri de integrale:

$$\int_0^L c_1 f(\alpha) d\alpha ;$$

$$\int_0^L c_2 \alpha f(\alpha) d\alpha ; \quad \text{și}$$

$$\int_0^L c_3 \alpha^2 f(\alpha) d\alpha$$

Tinînd seama că  $f(\alpha)$  este funcția de densitate pentru repartiția de tip  $\Gamma$  :

$$f(\alpha) = \frac{1}{\Gamma(\beta)} \zeta(\zeta\alpha)^{\beta-1} e^{-\zeta\alpha}$$

pentru cele 3 tipuri de integrale se obțin valorile următoare:

Pentru primul tip:

$$\int_0^L c_1 \frac{1}{\Gamma(\beta)} \zeta(\zeta\alpha)^{\beta-1} e^{-\zeta\alpha} d\alpha = c_1 \frac{1}{\Gamma(\beta)} \int_0^L (\zeta\alpha)^{\beta-1} e^{-\zeta\alpha} d(\zeta\alpha) = c_1 I[\zeta L; \beta] \quad (47)$$

Pentru următoarele două tipuri de integrale, conform relațiilor (22) și (23) se obțin:

$$\int_0^L c_2 \alpha f(\alpha) d\alpha = c_2 \frac{\beta}{\zeta} I[\zeta L, \beta+1] \quad \text{și} \quad (48)$$

$$\int_0^L c_3 \alpha^2 f(\alpha) d\alpha = c_3 \frac{(\beta+1)\beta}{2\zeta^2} I[\zeta L; \beta+2] \quad (49)$$

Aplicând relațiile (47) - (49) pentru integralele din partea dreaptă a expresiei (45), funcțiile  $\Pi_i(\alpha)$  avînd forma (46), se obține:

$$\begin{aligned} M[DP(\alpha)] = & a \frac{(\beta+1)^\beta}{2} I[\zeta(s-p); \beta+2] + b \frac{\beta}{\zeta} I[\zeta(s-p); \beta+1] + \\ & + c \frac{\beta}{\zeta} \{ I[\zeta s; \beta+1] - I[\zeta(s-p); \beta+1] \} + \\ & + d \{ I[\zeta s; \beta] - I[\zeta(s-p); \beta] \} + e \frac{\beta}{\zeta} \{ I[\zeta p \left| \frac{p}{p} \right|; \beta+1] - I[\zeta s; \beta+1] \} \\ & + f \{ I[\zeta p \left| \frac{p}{p} \right|; \beta] - I[\zeta s; \beta] \} \end{aligned} \quad (50)$$

Coeficienții a - f au valorile:

$$\begin{aligned} a &= \frac{1}{p^2} \cdot \frac{1}{2 \left| \frac{p}{p} \right|} ; \\ b &= \frac{1}{p} \left( 1 - \frac{s}{p \left| \frac{p}{p} \right|} - \frac{1}{2 \left| \frac{p}{p} \right|} \right) ; \\ c &= \frac{s}{p^2} (\sigma - 1) + \frac{1}{p} \left( 1 - \frac{1}{\left| \frac{p}{p} \right|} \right) ; \\ d &= \left( \sigma - 1 + \frac{1}{2 \left| \frac{p}{p} \right|} \right) \left( - \frac{s^2}{p^2} + \frac{s}{p} \right) ; \\ e &= \frac{\sigma}{p} \\ f &= \frac{1}{2 \left| \frac{p}{p} \right|} \left( \frac{s^2}{p^2} + \frac{s}{p} \right) \end{aligned} \quad (51)$$

În continuare vom obține o expresie echivalentă cu (50) pentru determinarea numărului mediu de defecte de pagină, dar în care toate funcțiile  $\Gamma$  incomplete de forma  $I(\pi; \pi)$  să aibă parametrii  $\pi$  egali. Deci dorim a determina expresii echivalente pentru integralele (48) și (49).

Astfel:

$$I_{48} = \int_0^L c \alpha f(\alpha) d\alpha = c \frac{1}{\Gamma(\beta)} \int_0^L (\zeta \alpha)^\beta e^{-\zeta \alpha} d\alpha = c \frac{1}{\zeta} \cdot \frac{1}{\Gamma(\beta)} \int_0^L x^\beta e^{-x} dx$$

Integrând prin părți:

$$\begin{aligned} x^\beta &= u & e^{-x} dx &= dv \\ du &= \beta x^{\beta-1} dx & v &= -e^{-x} \end{aligned}$$

$$\begin{aligned} I_{43} &= C \frac{1}{\xi} \frac{1}{\Gamma(\beta)} \left\{ -x^\beta e^{-x} \Big|_0^{\xi L} + \beta \int_0^{\xi L} x^{\beta-1} e^{-x} dx \right\} = \\ &= -C \frac{1}{\xi} \frac{1}{\Gamma(\beta)} (\xi L)^\beta e^{-\xi L} + C \frac{\beta}{\xi} I[\xi L; \beta] \end{aligned} \quad (43 a)$$

Iar

$$\begin{aligned} I_{49} &= \int_0^L C x^{\beta+1} f(x) dx = C \frac{1}{\xi} \frac{1}{\Gamma(\beta)} \int_0^L (\xi x)^{\beta+1} e^{-\xi x} dx = \\ &= C \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} \int_0^{\xi L} x^{\beta+1} e^{-x} dx \end{aligned}$$

Integrând prin părți:

$$\begin{aligned} x^{\beta+1} &= u & e^{-x} dx &= dv \\ du &= (\beta+1) x^\beta dx & v &= -e^{-x} \end{aligned}$$

$$\begin{aligned} I_{49} &= C \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} \left\{ -x^{\beta+1} e^{-x} \Big|_0^{\xi L} + (\beta+1) \int_0^{\xi L} x^\beta e^{-x} dx \right\} = \\ &= -C \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} (\xi L)^{\beta+1} e^{-\xi L} + C \frac{\beta+1}{\xi^2} \frac{1}{\Gamma(\beta)} \int_0^{\xi L} x^\beta e^{-x} dx \end{aligned}$$

Pentru integrala din partea dreaptă putem aplica egalitatea (43 a) stabilită mai sus, deci:

$$\begin{aligned} I_{49} &= -C \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} (\xi L)^{\beta+1} e^{-\xi L} + C \frac{\beta+1}{\xi^2} \left[ -\frac{1}{\Gamma(\beta)} (\xi L)^\beta e^{-\xi L} + \right. \\ &\quad \left. + \beta I[\xi L; \beta] \right] \quad \text{sau:} \\ I_{49} &= -C \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} e^{-\xi L} (\xi L)^\beta [\xi L + (\beta+1)] + C \frac{(\beta+1)^\beta}{\xi^2} I[\xi L; \beta] \end{aligned} \quad (49 a)$$

Aplicând relațiile (48 a) și (49 a) pentru exprimarea funcțiilor  $\Gamma$  incomplete din relația (50) se obține următoarea formă echivalentă:



$$\begin{aligned}
 M[DP(\alpha)] = & -a \cdot \frac{1}{\xi^2} \cdot \frac{1}{\Gamma(\beta)} [\xi(s-p)]^\beta e^{-\xi(s-p)} [\xi(s-p) + (\beta+1)] + \\
 & + a \frac{(\beta+1)^\beta}{\xi^2} I[\xi(s-p); \beta] - b \cdot \frac{1}{\xi} \cdot \frac{1}{\Gamma(\beta)} [\xi(s-p)]^\beta e^{-\xi(s-p)} + \\
 & + b \cdot \frac{\xi}{\xi} I[\xi(s-p); \beta] + c \left\{ -\frac{1}{\xi} \frac{1}{\Gamma(\beta)} [\xi s]^\beta e^{-\xi s} + \right. \\
 & + \frac{1}{\xi} \frac{1}{\Gamma(\beta)} [\xi(s-p)]^\beta e^{-\xi(s-p)} + \frac{\beta}{\xi} I[\xi s; \beta] - \frac{\beta}{\xi} I[\xi(s-p); \beta] \left. \right\} + \\
 & + d \left\{ I[\xi s; \beta] - I[\xi(s-p); \beta] \right\} + e \left\{ -\frac{1}{\xi} \frac{1}{\Gamma(\beta)} \left[ \xi p \left[ \frac{p}{p} \right] \right]^\beta e^{-\xi p \left[ \frac{p}{p} \right]} \right. \\
 & + \frac{1}{\xi} \frac{1}{\Gamma(\beta)} [\xi s]^\beta e^{-\xi s} + \frac{\beta}{\xi} I[\xi p \left[ \frac{p}{p} \right]; \beta] - \frac{\beta}{\xi} I[\xi s; \beta] \left. \right\} + \\
 & + f \left\{ I[\xi p \left[ \frac{p}{p} \right]; \beta] - I[\xi s; \beta] \right\} \quad (52)
 \end{aligned}$$

Grupînd termenii în partea dreaptă:

$$\begin{aligned}
 M[DP(\alpha)] = & \frac{1}{\xi} \frac{1}{\Gamma(\beta)} [\xi(s-p)]^\beta e^{-\xi(s-p)} \left[ -a(s-p) - \frac{a(\beta+1)}{\xi} - b + c \right] + \\
 & + \frac{1}{\xi} \cdot \frac{1}{\Gamma(\beta)} [\xi s]^\beta e^{-\xi s} [-c + e] + \frac{1}{\xi} \frac{1}{\Gamma(\beta)} \left[ \xi p \left[ \frac{p}{p} \right] \right]^\beta e^{-\xi p \left[ \frac{p}{p} \right]} (-e) + \\
 & + I[\xi(s-p); \beta] \left[ a \frac{(\beta+1)^\beta}{\xi^2} + b \cdot \frac{\beta}{\xi} - c \frac{\beta}{\xi} - d \right] + \\
 & + I[\xi s; \beta] \left[ c \frac{\beta}{\xi} + d - e \frac{\beta}{\xi} - f \right] + I[\xi p \left[ \frac{p}{p} \right]; \beta] \left[ e \frac{\beta}{\xi} + f \right] \quad (53)
 \end{aligned}$$

Relațiile echivalente (50) și (53) reprezintă expresia analitică căutată de noi care determină numărul de defecte de pagină care apar în decursul executării unui program într-un mediu cu memorie virtuală. Aceste expresii vor fi de importanță centrală în cele ce urmează.

## 2.6. Validarea modelului elaborat.

Modelul comportării de acces a unui program într-un mediu cu memorie virtuală construit mai sus este verificat în continuare prin faptul că pe baza lui se regăsesc pe cale analitică:

(1) caracteristicile calitative ale funcției ce determină numărul defectelor de pagină generate la execuția unui program, caracteristici observate în cadrul unor studii de simulare publicate;

(2) rezultatele numerice experimentale.

### 2.6.1. Proprietățile funcției DPA.

În cadrul unui sistem ce adoptă paginarea la cerere un program își începe execuția având o singură pagină dispusă în memoria principală; pentru satisfacerea necesităților de instrucții și date restul de pagini ale programului va fi adus în memoria principală treptat. La începutul execuției programul produce defecte de pagină la intervale de execuție foarte scurte; după ce programul a acumulat un număr suficient de pagini din cerința lui totală de pagini se observă intervale mai mari de execuție.

Astfel, studiul de simulare (72) stabilește că:

- programele tind să ceară pagini cu rate mari până la obținerea unei suficiențe de pagini;
- de obicei programele nu rulează foarte mult timp după ce au obținut o suficiență de pagini;
- pentru acele cereri de pagini ale programului, care conduc la timpi de rulare continui (fără alte cereri de pagini) importanți, o suficiență de pagini înlocuiește o fracțiune considerabilă din cererea de pagini totală a programului.

Studiile de simulare (40,72,75,102) prezintă mostre de referire a paginilor prin analiza șirului de referiri de pagină a unor programe tipice. Rezultatele prezentate în (40,72) sînt larg acceptate în cercetările actuale asupra comportării de acces a programelor în cadrul unui sistem cu paginare la cerere; o însumare a acestor rezultate este prezentată în fig.33 și 34.

Fig.33 este adaptată din studiile de simulare din (40). În lucrarea (40) au fost obținute rezultate separate pentru pagini de instrucții și pagini de date și ambele dovedesc caracteristici similare. Din fig.33 se observă că numărul de instrucții executate între defecte succesive de pagină crește de la  $R_1$  la  $R_2$  la o creștere a numărului de pagini acumulate de program de la  $A$  la  $C$ , la o valoare constantă  $D[A]$  a funcției de repartiție cumulative (FRS) a instrucțiilor executate între defecte succesive de pagină.




Fig.33. Funcția de repartiție cumulativă FRC a instrucțiilor executate între defecte succesive de pagină.

$F[R] = P$  (numărul de instrucții executate între defecte succesive de pagină  $\leq R$ );

$K$  = numărul de pagini acumulate de program;

$R$  = numărul de instrucții executate.

Programe tipice analizate au fost compilatorul WATFOR FORTRAN transformări FOURIER etc.

Fig.34 este adoptată din studiile de simulare din (72). Referințele la paginile de instrucții și la paginile de date nu au fost separate. Din fig.34 se observă că numărul paginilor cerute de program prin defecte de pagină este o funcție concavă în dependență de numărul de instrucții executate; această funcție își atinge asimptotic limita superioară. De asemenea se constată că în faza de început a execuției programului referirea la noi pagini se face într-un ritm rapid.




Fig.34. Cererea de pagini a unui program.

$K$  = numărul de pagini referite;

$R$  = numărul de instrucții executate.

Programe tipice analizate în obținerea acestor rezultate au fost Program de tratarea listelor LISP, compilatorul META 5 etc.

În termenii modelului elaborat de noi pentru comportarea de acces a unui program, cererea de pagini a unui program reprezintă numărul defectelor de pagină generate până la un anumit moment în execuția acestui program.

Ținând seama de rezultatele prezentate mai sus și obținute prin analiza unor șiruri de referiri de pagină, generate în cadrul execuției unor programe reale, pentru verificarea modelului elaborat va fi necesar să arătăm că el oferă posibilitatea de a stabili pe cale analitică următoarele 3 caracteristici ale funcției DPA (ce determină numărul defectelor de pagină generate la execuția unui program):

- 1 - DPA este o funcție concavă în dependența de numărul de instrucții executate;
- 2 - DPA are o asimptotă pentru valori mari ale numărului de instrucții executate;
- 3 - numărul de instrucții executate de program între defecte succesive de pagină crește cu numărul de pagini acumulate de program.

Vom stabili aceste proprietăți ale funcției DPA.

2.6.1.1. Proprietatea 1: DPA este o funcție concavă.

Fie relația (45) ce definește valoarea medie a numărului de defecte de pagină:

$$DPA = \int_0^{s-p} H_1(\alpha) f(\alpha) d\alpha + \int_{s-p}^s H_2(\alpha) f(\alpha) d\alpha + \int_s^{\left\lceil \frac{p}{p} \right\rceil} H_3(\alpha) f(\alpha) d\alpha \quad (54)$$

funcțiile  $H_1(\alpha)$  având forma:

$$H_1(\alpha) = a\alpha^2 + b\alpha$$

$$H_2(\alpha) = c\alpha + d$$

$$H_3(\alpha) = e\alpha + f$$

iar coeficienții  $a - f$  având valorile (51).

Prin intermediul coeficienților  $a-f$ , DPA este o funcție de dimensiunea programului (de numărul corespunzător de instrucții).

Calea ce o vom urma pentru a demonstra că DPA este o funcție concavă este de a arăta că  $\frac{d^2(DPA)}{dP^2} < 0$  și ca atare tangenta, în orice punct al graficului  $\frac{dP^2}{DPA(P)}$ , se află situată deasupra graficului.

Pentru simplificarea expresiilor analitice și fără a influența în nici un fel generalitatea rezultatelor, se poate presupune că dimensiunea programului P este multiplu întreg de dimensiunea paginii p. În acest caz, valorile coeficienților a-f devin:

$$\begin{aligned} a &= \frac{1}{2Pp} ; \\ b &= \frac{1}{p} - \frac{s}{Pp} - \frac{1}{2P} ; \\ c &= \frac{s}{p^2} (\sigma - 1) + \frac{1}{p} - \frac{1}{P} ; \\ d &= - (\sigma - 1) \frac{s^2}{p^2} + \frac{s}{p} (\sigma - 1 - \frac{s}{2P}) + \frac{s}{2P} ; \\ e &= \frac{\sigma}{p} ; \\ f &= - \frac{s^2}{2Pp} - \frac{s}{2P} \end{aligned} \quad (55)$$

Funcțiile  $H_i(\alpha)$  se pot transcrie:

$$\begin{aligned} H_1(\alpha) &= a\alpha^2 + b = \frac{1}{2Pp} \alpha^2 + (\frac{1}{p} - \frac{s}{Pp} - \frac{1}{2P})\alpha = \frac{1}{P} (\frac{\alpha^2}{2p} - \frac{s\alpha}{p} - \frac{\alpha}{2}) + \frac{\alpha}{p} \\ H_2(\alpha) &= c\alpha + d = \frac{s}{p^2} (\sigma - 1) + \frac{\alpha}{p} - \frac{\alpha}{P} - (\sigma - 1) \frac{s^2}{p^2} + \frac{s}{p} (\sigma - 1 - \frac{s}{2P}) + \frac{s}{2P} \\ &= \frac{1}{P} (-\alpha - \frac{s^2}{2p} + \frac{s}{2}) + [\frac{s(\sigma - 1)}{p^2} + \frac{1}{p}] \alpha - (\sigma - 1) \frac{s^2}{p^2} + \frac{s}{p} (\sigma - 1) ; \\ H_3(\alpha) &= e\alpha + f = \frac{\sigma}{p} \alpha - \frac{s^2}{2Pp} - \frac{s}{2P} = \frac{1}{P} (-\frac{s^2}{2p} - \frac{s}{2}) + \frac{\sigma}{p} \alpha. \end{aligned} \quad (56)$$

Expresia (54) devine, considerînd-o funcție de P:

$$\begin{aligned} DPA(P) &= \int_0^{s-p} \left[ \frac{1}{P} (\frac{\alpha^2}{2p} - \frac{s\alpha}{p} - \frac{\alpha}{2}) + \frac{\alpha}{p} \right] f(\alpha) d\alpha + \int_{s-p}^s \left\{ \frac{1}{P} (-\alpha - \frac{s^2}{2p} + \frac{s}{2}) + \right. \\ &+ \left. [\frac{s(\sigma - 1)}{p^2} + \frac{1}{p}] \alpha - (\sigma - 1) \frac{s^2}{p^2} + \frac{s}{p} (\sigma - 1) \right\} f(\alpha) d\alpha + \\ &+ \int_s^P \left[ \frac{1}{P} (-\frac{s^2}{2p} - \frac{s}{2}) + \frac{\sigma}{p} \right] f(\alpha) d\alpha = T_1 + T_2 + T_3 \end{aligned} \quad (57)$$

Calculăm separat derivatele secunde după  $p$  ale celor trei termeni  $E_1$  din partea dreaptă a expresiei (57).

Astfel:

$$\begin{aligned} \frac{d^2 E_1}{dp^2} &= \int_0^{s-p} \frac{2}{p^3} \left( \frac{\alpha^2}{2p} - \frac{s\alpha}{p} - \frac{\alpha}{2} \right) f(\alpha) d\alpha = \\ &= \frac{1}{p^3} \cdot \frac{1}{p} \int_0^{s-p} \alpha^2 f(\alpha) d\alpha - \frac{1}{p^3} \cdot \frac{2s+p}{p} \int_0^{s-p} \alpha f(\alpha) d\alpha = \\ &= \frac{1}{p^3} \cdot \frac{1}{p} \int_0^{s-p} \alpha^2 \frac{\xi^\rho}{\Gamma(\rho)} \alpha^{\rho-1} e^{-\xi\alpha} d\alpha - \frac{1}{p^3} \cdot \frac{2s+p}{p} \cdot \\ &\quad \cdot \int_0^{s-p} \alpha f(\alpha) d\alpha \quad (58) \end{aligned}$$

Prin integrală devine:

$$\begin{aligned} \frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\Gamma(\rho)} \int_0^{s-p} \xi^\rho \alpha^{\rho+1} e^{-\xi\alpha} d\alpha &= \frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\Gamma(\rho)} \frac{1}{\xi^2} \int_0^{s-p} (\xi\alpha)^{\rho+1} e^{-\xi\alpha} d(\xi\alpha) \\ &= \frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\Gamma(\rho)} \frac{1}{\xi^2} \int_0^{\xi(s-p)} x^{\rho+1} e^{-x} dx \end{aligned}$$

Integrând prin părți:

$$\begin{aligned} u &= x^{\rho+1} = u & e^{-x} dx &= dv \\ du &= (\rho+1)x^\rho dx & v &= -e^{-x} \end{aligned}$$

$$\begin{aligned} \frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\Gamma(\rho)} \frac{1}{\xi^2} \left\{ \left. -x^{\rho+1} e^{-x} \right|_0^{\xi(s-p)} + \int_0^{\xi(s-p)} (\rho+1) x^\rho e^{-x} dx \right\} &= \\ = -\frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\xi^2} \frac{1}{\Gamma(\rho)} [\xi(s-p)]^{\rho+1} e^{-\xi(s-p)} + \frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\xi^2} \frac{\rho+1}{\Gamma(\rho)} \cdot \\ \cdot \int_0^{\xi(s-p)} x^{(\rho+1)-1} e^{-x} dx &= -\frac{1}{p^3} \cdot \frac{1}{p} \frac{1}{\xi^2} \frac{1}{\Gamma(\rho)} [\xi(s-p)]^{\rho+1} e^{-\xi(s-p)} + \\ + \frac{1}{p^3} \cdot \frac{1}{p} \frac{\rho(\rho+1)}{\xi^2} I[\xi(s-p); \rho+1] &\quad (59) \end{aligned}$$

A doua integrală din expresia (58) devine, conform relației (43):

$$\frac{1}{p^3} \frac{2s+p}{p} \int_0^{s-p} \alpha f(\alpha) d\alpha = \frac{1}{p^3} \frac{2s+p}{p} \frac{\beta}{\xi} I[\xi(s-p); \beta+1] \quad (56)$$

Pe baza valorilor integralelor (55) și (56) se poate determina valoarea expresiei (53):

$$\frac{d^2 \pi_1}{d P^2} = - \frac{1}{p^3} \frac{1}{p} \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} [\xi(s-p)]^{\beta+1} e^{-\xi(s-p)} + \frac{1}{p^3} \frac{1}{p} \cdot$$

$$\begin{aligned} & \cdot \frac{\beta(\beta+1)}{\xi^2} I[\xi(s-p); \beta+1] - \frac{1}{p^3} \frac{2s+p}{p} \frac{\beta}{\xi} I[\xi(s-p); \beta+1] = \\ & = - \frac{1}{p^3} \frac{1}{p} \frac{1}{\xi^2} \frac{1}{\Gamma(\beta)} [\xi(s-p)]^{\beta+1} e^{-\xi(s-p)} - \\ & - \frac{1}{p^3} \frac{1}{p} \frac{\beta}{\xi} I[\xi(s-p); \beta+1] \left[ (2s+p) - \frac{\beta+1}{\xi} \right] \end{aligned}$$

Intrucât, în mod obișnuit  $2s+p > \frac{\beta+1}{\xi} \approx$  lungimea medie a ciclurilor programului, rezultă că:

$$\frac{d^2 \pi_1}{d P^2} < 0 \quad (61)$$

Trecem la calculul derivatei secunde după  $P$  a termenului al doilea din (57):

$$\begin{aligned} \frac{d^2 \pi_2}{d P^2} &= \int_{s-p}^s \frac{2}{p^3} \left( -\alpha - \frac{s^2}{2p} + \frac{s}{2} \right) f(\alpha) d\alpha = \\ &= - \frac{2}{p^3} \int_{s-p}^s \alpha f(\alpha) d\alpha - \frac{1}{p^3} \frac{s}{p} \cdot (s-p) \int_{s-p}^s f(\alpha) d\alpha \quad (62) \end{aligned}$$

Deoarece integralele  $\int_{s-p}^s \alpha f(\alpha) d\alpha$  și  $\int_{s-p}^s f(\alpha) d\alpha$  sînt pozitive, conform (47) și (48),

$$\int_{s-p}^s \alpha f(\alpha) d\alpha = \frac{\beta}{\xi} \left\{ I[\xi s; \beta+1] - I[\xi(s-p); \beta+1] \right\}$$

$$\int_{s-p}^s f(\alpha) d\alpha = I[\xi s; \beta] - I[\xi(s-p); \beta]$$

pe baza (62) rezultă că:

$$\frac{d^2 \pi_2}{dP^2} < 0 \quad (63)$$

În final ne rămâne a determina derivata a doua a ultimului termen din expresia (57).

$$\begin{aligned} & \frac{d^2}{dP^2} \int_s^P \left[ \frac{1}{P} \left( -\frac{s^2}{2P} - \frac{s}{P} \right) + \frac{\sigma}{P} \alpha \right] f(\alpha) d\alpha = \\ & = -\frac{s}{2P} (s+p) \frac{d^2}{dP^2} \int_s^P \frac{1}{P} f(\alpha) d\alpha + \frac{\sigma}{P} \frac{d^2}{dP^2} \int_s^P \alpha f(\alpha) d\alpha = \\ & = -\frac{s}{2P} (s+p) \left[ \frac{2}{P^3} \int_s^P f(\alpha) d\alpha - \frac{2}{P^2} f(P) + \frac{1}{P} f'(P) \right] + \frac{\sigma}{P} \left[ f(P) + P f'(P) \right] = \\ & = -\frac{s}{2P} (s+p) \frac{2}{P^3} \int_s^P f(\alpha) d\alpha + \frac{s(s+p)}{P P^2} \left[ f(P) - \frac{P}{2} f'(P) \right] + \frac{\sigma}{P} \left[ f(P) + P f'(P) \right] \end{aligned} \quad (64)$$

În expresia de mai sus primul termen este evident negativ, căci integrala  $\int_s^P f(\alpha) d\alpha$  este pozitivă, funcția  $f(\alpha)$  fiind pozitivă, iar  $P > s$ .

Relativ la ultimii doi termeni din expresia (64) ei pot fi transformați în modul următor:

$$\begin{aligned} & \frac{s(s+p)}{P P^2} \left[ f(P) - \frac{P}{2} f'(P) \right] + \frac{\sigma}{P} \left[ f(P) + P f'(P) \right] = \\ & = \frac{\sigma}{P} \left\{ \frac{1}{\sigma} \cdot \frac{s(s+p)}{P^2} \left[ f(P) - \frac{P}{2} f'(P) \right] + \left[ f(P) + P f'(P) \right] \right\} \end{aligned} \quad (65)$$

$$\text{Notăm } \frac{1}{\sigma} \cdot \frac{s(s+p)}{P^2} = \gamma$$

Relativ la mărimea lui  $\gamma$  se pot face următoarele considerații: Întrucât valoarea  $\sigma$ , care reprezintă numărul de ori de care un ciclu  $\alpha$  este apelat, are valoarea:

$$\sigma \gg 1,$$

iar

$$\frac{s(s+p)}{P^2} < 1 \quad (\text{căci } s < P)$$

rezultă că:

$$\gamma \ll 1$$

Expresia (65) devine:



$$\frac{\sigma}{P} \left\{ \gamma \left[ f(P) - \frac{P}{\gamma} f'(P) \right] + \left[ f(P) + P f'(P) \right] \right\} = \frac{\sigma}{P} \left[ f(P)(\gamma+1) + P f'(P)(1-f) \right] \quad (66)$$

Determinăm  $f'(P)$

$f(P)$  este cunoscută ca:

$$f(P) = \frac{\xi^\beta}{\Gamma(\beta)} P^{\beta-1} e^{-\xi P} \quad (67)$$

deci:

$$\begin{aligned} f'(P) &= \frac{\xi^\beta}{\Gamma(\beta)} \left[ (\beta-1) P^{\beta-2} e^{-\xi P} + P^{\beta-1} (-\xi) e^{-\xi P} \right] = \\ &= \frac{\xi^\beta}{\Gamma(\beta)} P^{\beta-1} e^{-\xi P} \left( \frac{\beta-1}{P} - \xi \right) = f(P) \left( \frac{\beta-1}{P} - \xi \right) \quad (68) \end{aligned}$$

Înlocuind (68) în (66) se obține:

$$\frac{\sigma}{P} f(P) \left[ (\gamma+1) + P \left( \frac{\beta-1}{P} - \xi \right) (1-f) \right] = \frac{\sigma}{P} f(P).$$

$$\cdot \left[ (\gamma+1) + (\beta-1) \left( 1 - \frac{f}{2} \right) - P \xi \left( 1 - \frac{f}{2} \right) \right] \quad (69)$$

Se poate arăta ușor că paranteza mare este negativă, căci:

$$P > \frac{(\gamma+1) + (\beta-1) \left( 1 - \frac{f}{2} \right)}{\xi \left( 1 - \frac{f}{2} \right)} \quad (70)$$

Inegalitatea (70) rezultă astfel: s-a arătat mai sus că  $\gamma \ll 1$ , deci  $\gamma$  poate fi omis în parantezele  $(\gamma+1)$  și  $(1 - \frac{f}{2})$ ; ca urmare trebuie arătat că:

$$P > \frac{\beta}{\xi}$$

ori acest lucru este evident:  $\frac{\beta}{\xi}$  reprezintă valoarea medie a lunginii ciclurilor programului, iar dimensiunea programului este în mod firesc mai mare ca această lungime medie a ciclurilor componente.

Dovedind că suma celor trei termeni ai expresiei (64) este negativă, s-a demonstrat că:

$$\frac{d^2 \pi_2}{dP^2} < 0 \quad (71)$$

ținând seama de relațiile (61), (63) și (71) rezultă că:

$$\frac{d^2 [DPA(P)]}{dP^2} < 0$$

./.

și ca un mare DPA(P) este o funcție concavă relativ la numărul de instrucții executate.

2.6.1.2. Proprietatea 2: DPA are o asimptotă pentru valori mari ale numărului de instrucții executate.

Fie o dimensiune mare P a unui program ce se execută. In acest caz, coeficienții a-f (55) devin:

$$\begin{aligned}
 a &= 0 ; \\
 b &= \frac{1}{p} ; \\
 c &= \frac{s}{p^2} (\sigma - 1) + \frac{1}{p} ; \\
 d &= - (\sigma - 1) \frac{s}{p} \left( \frac{s}{p} - 1 \right) ; \\
 e &= \frac{\sigma}{p} \text{ și} \\
 f &= 0
 \end{aligned}
 \tag{72}$$

Relativ la forma și valoarea unor termeni în expresia (53), în această situație, se observă:

$$\lim_{P \rightarrow \infty} \frac{1}{\xi} \frac{1}{\Gamma(\beta)} \frac{\left[ \xi p \left| \frac{P}{p} \right| \right]^\beta}{e^{\xi p \left| \frac{P}{p} \right|}} = 0$$

iar

$$-b + c = \frac{s}{p^2} (\sigma - 1)$$

$$-c + e = -\frac{s}{p^2} (\sigma - 1) - \frac{1}{p} + \frac{\sigma}{p} = -\frac{(\sigma - 1)}{p} \left( \frac{s}{p} - 1 \right)$$

$$\begin{aligned}
 b \frac{\beta}{\xi} - c \frac{\beta}{\xi} - d &= \frac{1}{p} \frac{\beta}{\xi} - \frac{\beta}{\xi} \left[ \frac{s}{p^2} (\sigma - 1) + \frac{1}{p} \right] + (\sigma - 1) \frac{s}{p} \left( \frac{s}{p} - 1 \right) = \\
 &= \frac{s}{p} (\sigma - 1) \left( -\frac{\beta}{\xi p} + \frac{s}{p} - 1 \right)
 \end{aligned}$$

$$\begin{aligned}
 c \frac{\beta}{\xi} + d - e \frac{\beta}{\xi} &= d + \frac{\beta}{\xi} (c - e) = -(\sigma - 1) \frac{s}{p} \left( \frac{s}{p} - 1 \right) + \frac{\beta}{\xi} \frac{\sigma - 1}{p} \left( \frac{s}{p} - 1 \right) = \\
 &= \frac{\sigma - 1}{p} \left( \frac{s}{p} - 1 \right) \left( \frac{\beta}{\xi} - s \right)
 \end{aligned}$$

$$\lim_{P \rightarrow \infty} I \left[ \xi p \left| \frac{P}{p} \right| ; \beta \right] = \frac{1}{\Gamma(\beta)} \Gamma(\beta) = 1$$

./.

Expresia (53) devine:

$$\begin{aligned} \lim_{P \rightarrow \infty} M[DP(\infty)] &= \frac{1}{\xi} \frac{1}{\Gamma(\beta)} [\xi(s-p)]^\beta e^{-\xi(s-p)} \cdot \frac{s}{p^2} (\beta-1) + \\ &+ \frac{1}{\xi} \frac{1}{\Gamma(\beta)} [\xi s]^\beta e^{-\xi s} \left(-\frac{\beta-1}{p}\right) \left(\frac{s}{p} - 1\right) + \\ &+ I[\xi(s-p); \beta] \frac{s}{p} (\beta-1) \left(-\frac{\beta}{\xi p} + \frac{s}{p} - 1\right) + \\ &+ I[\xi s, \beta] \frac{\beta-1}{p} \left(\frac{s}{p} - 1\right) \left(\frac{\beta}{\xi} - s\right) + \frac{\xi}{p} \frac{\beta}{\xi}. \end{aligned}$$

Se observă deci că această limită există și este finită; valoarea acestei limite reprezintă asimptota funcției DDi.

2.6.1.3. Proprietatea 3: Numărul de instrucții executate de program între defecte succesive de pagină crește cu numărul de pagini acumulate de program.


Fie expresia (53) ce caracterizează numărul mediu al defectelor de pagină generate în cadrul execuției unui program cu dimensiunea de P instrucții. Ca și în cadrul analizei proprietății (1) a funcției DDi, vom presupune că P este un multiplu întreg de dimensiunea paginii.

Fie  $P_{i-1}$ ,  $P_i$  și  $P_{i+1}$  valorile dimensiunii P de program ce conduc la apariția a unui număr de (i-1), i și respectiv (i+1) defecte de pagină. Forma pe care o ia expresia (53) în cele trei cazuri va fi:

$$\begin{aligned} i-1 &= k_1 + k_2 \Psi\left(\frac{1}{P_{i-1}}\right) + k_3 \Phi\left(\frac{1}{P_{i-1}}\right) \int_0^{P_{i-1}} x^{\beta-1} e^{-\xi x} dx \\ i &= k_1 + k_2 \Psi\left(\frac{1}{P_i}\right) + k_3 \Phi\left(\frac{1}{P_i}\right) \int_0^i x^{\beta-1} e^{-\xi x} dx \quad (73) \\ i+1 &= k_1 + k_2 \Psi\left(\frac{1}{P_{i+1}}\right) + k_3 \Phi\left(\frac{1}{P_{i+1}}\right) \int_0^{P_{i+1}} x^{\beta-1} e^{-\xi x} dx \end{aligned}$$

unde  $k_1$ ,  $k_2$  și  $k_3$  sînt expresii cu valori constante în cele trei relații (73), iar  $\Psi\left(\frac{1}{P}\right)$  și  $\Phi\left(\frac{1}{P}\right)$  sînt funcții de  $\frac{1}{P}$ , obținute prin intermediul coeficienților a-f (51).

Scăzînd, între ele, primele și ultimile două egalități (73) se obține:



$$K_2 \left[ \Psi\left(\frac{1}{P_i}\right) - \Psi\left(\frac{1}{P_{i-1}}\right) \right] = \left[ \phi\left(\frac{1}{P_i}\right) \int_0^{P_i} x^{\beta-1} e^{-\xi x} dx - \phi\left(\frac{1}{P_{i-1}}\right) \int_0^{P_{i-1}} x^{\beta-1} e^{-\xi x} dx \right]$$

$$K_2 \left[ \Psi\left(\frac{1}{P_{i+1}}\right) - \Psi\left(\frac{1}{P_i}\right) \right] = \left[ \phi\left(\frac{1}{P_{i+1}}\right) \int_0^{P_{i+1}} x^{\beta-1} e^{-\xi x} dx - \phi\left(\frac{1}{P_i}\right) \int_0^{P_i} x^{\beta-1} e^{-\xi x} dx \right] = 1 \quad (74)$$

Ținând seama că  $\Psi\left(\frac{1}{P}\right)$  și  $\phi\left(\frac{1}{P}\right)$  sînt funcții de  $\frac{1}{P}$  diferențele între două valori ale acestor funcții pentru argumentele  $(i-1; i)$  și  $(i; i+1)$  vor consta în termeni de forma:

$$\sum_j \left( \frac{K_j}{P_{i+1}^{j+1}} - \frac{K_j}{P_i^{j+1}} \right) = \sum_j \Gamma_j \left( \frac{1}{P_{i+1}} - \frac{1}{P_i} \right) \quad (75)$$

Deoarece:  $P_{i+1} = P_i + \Delta P_i$ , expresia (75) se poate scrie:

$$\sum_j \Gamma_j \frac{P_i^{j+1} - (P_i + \Delta P_i)^{j+1}}{P_i^{j+1} \cdot P_{i+1}^{j+1}} \approx \sum_j \Gamma_j' \frac{(-P_i^{-j-1}) \Delta P_i}{P_i^{j+1}} = - \sum_j \Gamma_j' \frac{\Delta P_i}{P_i^{j+1}}$$

Pentru dimensiuni  $P$  suficient de mari ale programului, acești termeni sînt foarte mici și ca atare se poate aproxima, pentru  $P_i$  mari:

$$\begin{aligned} \Psi\left(\frac{1}{P_{i-1}}\right) &\approx \Psi\left(\frac{1}{P_i}\right) \approx \Psi\left(\frac{1}{P_{i+1}}\right) \\ \phi\left(\frac{1}{P_{i-1}}\right) &\approx \phi\left(\frac{1}{P_i}\right) \approx \phi\left(\frac{1}{P_{i+1}}\right) \end{aligned} \quad (76)$$

Scăzînd acum între ele egalitățile (74) și utilizînd (76) se obține relația:

$$\int_{P_{i-1}}^{P_i} x^{\beta-1} e^{-\xi x} dx = \int_{P_i}^{P_{i+1}} x^{\beta-1} e^{-\xi x} dx \quad (77)$$

$$\text{Fie: } f(x) = \int x^{\beta-1} e^{-\xi x} dx$$

iar  $f(m_i)$  și  $f(m_{i+1})$  valorile medii ale acestei funcții pe intervalele:

$$\begin{aligned} [P_{i-1}; P_i] \\ [P_i; P_{i+1}] \end{aligned} \quad \text{respectiv}$$

Utilizînd pentru calculul integralelor din relația (77) o formulă de medie, obținem egalitatea:

$$(P_i - P_{i-1}) f(m_i) = (P_{i+1} - P_i) f(m_{i+1}) \quad (78)$$

Derivându-ne pe termenul derivatei

$$f'(x) = x^{p-2} e^{-qx} [k(p-1) - qx]$$

care pentru  $x > \frac{p-1}{q}$  este negativă, rezultă că funcția  $f(x)$  este descrescătoare pentru valori ale lui  $P$  mai mari ca  $P_0 = \frac{p-1}{q} \approx$  valoarea medie a lungimii ciclurilor programului.

Valorile  $P_i$  considerate de noi se referă la dimensiuni ale programului ce satisfac  $P > P_0$ . În această situație, valoarea medie a  $f(x)$  pe intervalul  $(P_{i-1}, P_i)$  este mai mare ca valoarea medie a  $f(x)$  pe intervalul  $(P_i, P_{i+1})$

$$f(P_i) > f(P_{i+1}) \quad (79)$$

Tinând seama de (79), din (70) rezultă că:

$$P_{i+1} - P_i > P_i - P_{i-1}$$

relație ce atestă că numărul de instrucții executate de program între defectele succesive de pagină  $(i, i+1)$  este mai mare decât numărul de instrucții executate de program între defectele succesive de pagină  $(i-1, i)$ ; deci acest număr de instrucții crește cu numărul de pagini acumulate de program.

#### 2.6.2. Verificări experimentale.

Rezultate experimentale privind comportarea unor programe într-un mediu cu memorie virtuală au fost publicate în numeroase studii (40,72,75,76,102,111).

Vom stabili în cele ce urmează în ce măsură rezultatele publicate în aceste lucrări, ce se referă la numărul de defecte de pagină ce sînt generate în cadrul execuției unui program cu dimensiunea de  $P$  instrucții, pot fi regăsite cu ajutorul modelului propus al comportării de acces a programului.

Vom descrie procedura de lucru în acest scop, pentru un exemplu de program luat din (72), urmînd ca rezultatele obținute prin această procedură pentru alte programe să fie cuprinse într-un tabel (tabelul 5).

Astfel, pentru programul considerat:

$$p = 2 \text{ kbyte}$$

$$P = 10 \quad q = 20 \text{ kbyte}$$

$$L(\alpha) = 12 \quad K = 0,6 \text{ F}$$

$$D^2(\alpha) = \sum_{i=1}^n \frac{[\alpha_i - \bar{\alpha}]^2 \cdot n_i}{n} = 0,021 \text{ F}^2$$

$$\beta = \frac{V(\alpha)}{D^2(\alpha)} = \frac{0,26 \cdot 10^2}{0,021 \cdot 10^2} \approx 12$$

$$\xi = \frac{V(\alpha)}{D^2(\alpha)} = \frac{0,6 \cdot 10^2}{0,021 \cdot 10^2} \approx \frac{28}{1} \quad (30)$$

$$s = 10 \text{ K} = 0,5 \text{ I}$$

$$\xi = 20$$

Pentru comoditatea calculului ce urmează, vom adopta dimensiunea de pagină  $p$  ca unitate de referință pentru măsurile calculate.

Coefficienții  $a - f$  (51) au valorile:

$$a = \frac{1}{20}$$

$$b = \frac{5}{20}$$

$$c = \frac{950}{10}$$

$$d = -301$$

$$e = 20$$

(31)

$$f = -\frac{3}{2}$$

Pentru determinarea numărului mediu de defecte de pagină cu relația (50) se impune calculul funcțiilor  $\Gamma$  incomplete I  $[\pi, \beta]$ ,  $\pi$  și  $\beta$  fiind întregi, anume:

$$I[\pi, \beta] = \frac{1}{\Gamma(\beta)} \int_0^{\pi} y^{\beta-1} e^{-y} dy$$

Integrând prin părți:

$$y^{\beta-1} = u \quad e^{-y} dy = dv$$

$$du = (\beta-1) y^{\beta-2} dy \quad v = -e^{-y}$$

$$I[\pi, \beta] = \frac{1}{\Gamma(\beta)} \left[ -y^{\beta-1} e^{-y} \right]_0^{\pi} + \frac{1}{\Gamma(\beta)} (\beta-1) \int_0^{\pi} y^{\beta-2} e^{-y} dy =$$

$$= -\frac{1}{\Gamma(\beta)} \pi^{\beta-1} e^{-\pi} + \frac{1}{\Gamma(\beta-1)} \int_0^{\pi} y^{\beta-2} e^{-y} dy =$$

$$= -\frac{1}{\Gamma(\beta)} \pi^{\beta-1} e^{-\pi} + I[\pi, \beta-1] \quad (32)$$

./.

Scrind această relație de recurență pentru  $\beta$  descrescători:

$$I[x; \beta - 1] = - \frac{1}{\Gamma(\beta - 1)} x^{\beta - 2} e^{-x} + I[x; \beta - 2] \quad (83)$$

$$I[x, 3] = - \frac{1}{\Gamma(3)} x^2 e^{-x} + I[x, 2] \quad (84)$$

$$\begin{aligned} I[x, 2] &= - \frac{1}{\Gamma(2)} x e^{-x} + I[x, 1] = - \frac{1}{\Gamma(2)} x e^{-x} + \frac{1}{\Gamma(1)} \int_0^x e^{-y} dy = \\ &= - \frac{1}{\Gamma(2)} x e^{-x} + [-e^{-y}]_0^x = - \frac{1}{\Gamma(2)} x e^{-x} - e^{-x} + 1 \quad (85) \end{aligned}$$

Insumind relațiile (82-85):

$$\begin{aligned} I[x; \beta] &= - \frac{1}{\Gamma(\beta)} x^{\beta - 1} e^{-x} - \frac{1}{\Gamma(\beta - 1)} x^{\beta - 2} e^{-x} - \dots - \frac{1}{\Gamma(3)} x^2 e^{-x} - \\ &- \frac{1}{\Gamma(2)} x e^{-x} - e^{-x} + 1 = 1 - e^{-x} \left[ \frac{x^{\beta - 1}}{\Gamma(\beta)} + \frac{x^{\beta - 2}}{\Gamma(\beta - 1)} + \dots + \frac{x^2}{\Gamma(3)} + \frac{x}{\Gamma(2)} + 1 \right] \\ I[x; \beta] &= 1 - e^{-x} \left[ 1 + \frac{x}{1!} + \frac{x^2}{2!} + \dots + \frac{x^{\beta - 1}}{(\beta - 1)!} \right] \quad (86) \end{aligned}$$

Valorile numerice ale expresiei (86) pot fi foarte comod calculate cu ajutorul unui calculator. In cazul programului cercetat s-au determinat cu ajutorul programului GAMINC următoarele valori pentru funcțiile  $\Gamma$  incomplete  $I[x; \beta]$ , valori trecute în tabelul 4.

Tabelul 4

$x \backslash \beta$	18	19	20
12	0,0630	0,0374	0,0213
15	0,251	0,181	0,125
30	0,993	0,987	0,978

Expresia (50) devine, ținând seama de (80) și (81):

./.

$$\begin{aligned}
 DPA = & \frac{1}{20} \cdot \frac{18 \cdot 19}{9} I [12;20] + \frac{9}{20} \cdot \frac{18}{3} I [12;19] + \\
 & + \frac{959}{10} \cdot \frac{18}{3} \{ I [15;19] - I [12;19] \} - \\
 & - 381 \{ I [15;18] - I [12;18] \} + \\
 & + 20 \cdot \frac{18}{3} \{ I [30 ; 19] - I [15 ; 19] \} - \\
 & - \frac{3}{2} \{ I [30;18] - I [15;18] \} = 108
 \end{aligned}$$

Numărul de defecte de pagină raportat în (72) pentru acest program este 105, deci se poate constata o bună concordanță între rezultatul obținut cu ajutorul modelului și cel experimentat.

Tabelul 5 cuprinde rezultate relative la numărul de defecte de pagină generate în cadrul execuției unui program: coloana (e) se referă la rezultate experimentale comunicate în lucrările amintite, coloana (m) se referă la rezultatele obținute prin utilizarea modelului propus de comportare al programului.

Tabelul 5

Dimensiunea paginii	Dimensiunea programului	Alocarea	e	m	Datele experimentale din lucrarea
4 K	517 p	76 p	1.807	1.821	
		197 p	820	812	(93)
		512 p	517	523	
32 K	166 p	32 p	598	605	
		64 p	380	368	(70)

Pe baza rezultatelor din tabelul 5 se poate trage concluzia că modelul propus dă rezultate corecte.



**CAP.5. STUDIUL ANOMALIEI DIMENSIUNII DE PAGINA**

**1. Cercetarea anomaliei dimensiunii de pagină cu ajutorul modelului elaborat**

Fie expresia ce determină numărul mediu de defecte de pagină, care sînt generate în cadrul execuției unui program.

$$\begin{aligned}
 DPA = & a \frac{\beta(\beta+1)}{\xi^2} I[\xi(s-p); \beta+2] + b \cdot \frac{\beta}{\xi} I[\xi(s-p); \beta+1] + \\
 & + c \cdot \frac{\beta}{\xi} \{ I[\xi s; \beta+1] - I[\xi(s-p); \beta+1] \} + \\
 & + d \{ I[\xi s; \beta] - I[\xi(s-p); \beta] \} + \\
 & + e \frac{\beta}{\xi} \{ I[\xi p; \beta+1] - I[\xi s; \beta+1] \} + \\
 & + f \{ I[\xi p; \beta] - I[\xi s; \beta] \} \qquad (87)
 \end{aligned}$$

Această expresie este funcție de dimensiunea de pagină  $p$  utilizată, prin intermediul coeficienților a-f:

$$\begin{aligned}
 a &= \frac{1}{2Pp} ; \\
 b &= \frac{1}{p} - \frac{s}{Pp} - \frac{1}{2P} ; \\
 c &= \frac{s}{p^2} (\sigma-1) + \frac{1}{p} - \frac{1}{P} ; \\
 d &= - (\sigma-1) \frac{s^2}{p^2} + \frac{s}{p} (\sigma-1 - \frac{s}{2P}) + \frac{s}{2P} ; \\
 e &= \frac{\sigma}{p} ; \\
 f &= - \frac{s^2}{2Pp} - \frac{s}{2P} \qquad (88)
 \end{aligned}$$

În cadrul acestor expresii, ca și în capitolul precedent, secțiunea 2.6.1., s-a presupus - fără a afecta generalitatea rezultatelor - că dimensiunea programului  $P$  este multiplu întreg de dimensiunea paginii  $p$ . Notățiile folosite în cadrul expresiilor (87) și (88) sînt cele din cap.4.

Cercetarea cu ajutorul modelului elaborat al comportării de acces a unui program a anomaliei dimensiunii de pagină constă în determinarea cu ajutorul expresiei (87) a numărului de defecte de pagină care apar în cadrul execuției acestui program și uti-

lizării succesive a două dimensiuni de pagină,  $p$  și respectiv  $\frac{p}{k}$  (de  $k$  ori mai mică) și apoi analiza raportului numerelor acestor defecte:

$$\frac{DPA \left(\frac{p}{k}\right)}{k DPA(p)}$$

sau, ceea ce este similar, analiza semmului diferenței:

$$DIF = DPA \left(\frac{p}{k}\right) - k DPA(p) \quad (89)$$

Situația de anomalie a dimensiunii de pagină va apărea în cazul în care numărul defectelor de pagină generate la execuția programului și utilizarea unei dimensiuni de pagină  $\frac{p}{k}$  va fi de peste  $k$  ori mai mare decât numărul defectelor de pagină generate la execuția aceluiași program și utilizarea unei dimensiuni de pagină  $p$ , adică în cazul în care:

$$DIF > 0$$

Practic, pentru a determina valorile  $DPA \left(\frac{p}{k}\right)$  și  $DPA(p)$  ale expresiei (87), avem nevoie de valorile coeficienților  $a-f$  (88) în cazul utilizării celor două dimensiuni de pagină.

De altfel, (88) reprezintă valorile  $a-f$  pentru dimensiunea de pagină  $p$ . În cazul dimensiunii de pagină  $\frac{p}{k}$  valorile acestor coeficienți devin:

$$\begin{aligned} a^x &= k \cdot \frac{1}{2 Pp} ; \\ b^x &= k \left( \frac{1}{p} - \frac{s}{Pp} \right) - \frac{1}{2P} ; \\ c^x &= k^2 \cdot \frac{s(\sigma-1)}{p^2} + k \cdot \frac{1}{p} - \frac{1}{P} ; \\ d^x &= -k^2(\sigma-1) \frac{s^2}{p^2} + k \cdot \frac{s}{p} \left( \sigma - 1 - \frac{s}{2P} \right) + \frac{s}{2P} ; \\ e^x &= k \cdot \frac{\sigma}{p} ; \\ f^x &= -k \cdot \frac{s^2}{2 Pp} - \frac{s}{2P} \end{aligned} \quad (90)$$

Pe baza valorilor (88) și (90) se poate trece la determinarea diferenței (89):

$$\begin{aligned}
 \text{DIF} &= \frac{\beta}{\xi} I[\xi(s-p); \beta+1] \left( k \frac{1}{p} - k \frac{s}{p^2} - \frac{1}{2p} - k \frac{1}{p} + k \frac{s}{p^2} + k \frac{1}{2p} \right) + \\
 &+ \frac{\beta}{\xi} \left\{ I[\xi s; \beta+1] - I[\xi(s-p); \beta+1] \right\} \left( k^2 s \frac{\xi-1}{p^2} + k \frac{1}{p} - \frac{1}{p} - \right. \\
 &- k s \frac{\xi-1}{p^2} - k \frac{1}{p} + k \frac{1}{p} \left. \right) + \left\{ I[\xi s; \beta] - I[\xi(s-p); \beta] \right\} \cdot \\
 &\cdot \left[ -k^2 s^2 \frac{\xi-1}{p^2} + k s \frac{1}{p} \left( \xi-1 - \frac{s}{2p} \right) + \frac{s}{2p} + \right. \\
 &+ k s^2 \frac{\xi-1}{p^2} - k s \frac{1}{p} \left( \xi-1 - \frac{s}{2p} \right) - k \frac{s}{2p} \left. \right] + \\
 &+ \left\{ I[\xi p; \beta] - I[\xi s; \beta] \right\} \left( -k \frac{s^2}{2p^2} - \frac{s}{2p} + k \frac{s^2}{2p^2} + k \frac{s}{2p} \right)
 \end{aligned}$$

Efectuînd calculul parantezelor se obține:

$$\begin{aligned}
 \text{DIF} &= \frac{\beta}{\xi} I[\xi(s-p); \beta+1] \cdot \frac{1}{2p} (k-1) + \frac{\beta}{\xi} \left\{ I[\xi s; \beta+1] - \right. \\
 &- I[\xi(s-p); \beta+1] \left. \right\} (k-1) \left[ k s \frac{\xi-1}{p^2} + \frac{1}{p} \right] - \left\{ I[\xi s; \beta] - I[\xi(s-p); \beta] \right\} \cdot \\
 &\cdot s(k-1) \left[ k s \frac{\xi-1}{p^2} + \frac{1}{2p} \right] + \left\{ I[\xi p; \beta] - I[\xi s; \beta] \right\} \frac{s}{2p} (k-1)
 \end{aligned}$$

sau o formă identică:

$$\begin{aligned}
 \text{DIF} &= - \frac{\beta}{\xi} I[\xi(s-p); \beta+1] (k-1) \left[ k s \frac{\xi-1}{p^2} + \frac{1}{2p} \right] + \\
 &+ I[\xi(s-p); \beta] s(k-1) k s \left[ \frac{\xi-1}{p^2} + \frac{1}{2p} \right] + \frac{\beta}{\xi} I[\xi s; \beta+1] (k-1) \cdot \\
 &\cdot \left[ k s \frac{\xi-1}{p^2} + \frac{1}{p} \right] - I[\xi s; \beta] s(k-1) \left[ k s \frac{\xi-1}{p^2} + \frac{1}{p} \right] + \\
 &+ I[\xi p; \beta] \frac{s}{2p} (k-1) \tag{91}
 \end{aligned}$$

Funcția [ incompletă  $\frac{I[\xi(s-p); \beta+1]}{\xi(s-p)}$

$$I[\xi(s-p); \beta+1] = \frac{1}{\Gamma(\beta+1)} \int_0^{\xi(s-p)} x^{(\beta+1)-1} e^{-x} dx$$

poate fi transformată, prin integrare prin părți, astfel:

$$\begin{aligned}
 u &= x^\beta & dv &= e^{-x} dx \\
 du &= \beta x^{\beta-1} dx & v &= -e^{-x}
 \end{aligned}$$

v/.

$$I[\xi^{(s-p)}; \beta+1] = \frac{1}{\Gamma(\beta+1)} \left| -x^\beta e^{-x} \right|_0^{(s-p)} + \frac{\xi^{(s-p)}}{\Gamma(\beta+1)} \int_0^\xi x^{\beta-1} e^{-x} dx =$$

$$= -\frac{1}{\Gamma(\beta+1)} [\xi^{(s-p)}]^\beta e^{-\xi^{(s-p)}} + I[\xi^{(s-p)}; \beta] \quad (92)$$

În mod asemănător, rezultă:

$$I[\xi^s; \beta+1] = -\frac{1}{\Gamma(\beta+1)} [\xi^s]^\beta e^{-\xi^s} + I[\xi^s; \beta] \quad (93)$$

Înlocuind (92) și (93) în expresia (91) se obține:

$$\begin{aligned} \text{DIF} = & \frac{\beta}{\xi} \frac{1}{\Gamma(\beta+1)} [\xi^{(s-p)}]^\beta e^{-\xi^{(s-p)}} (k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{2p} \right] - \\ & - \frac{\beta}{\xi} \frac{1}{\Gamma(\beta+1)} [\xi^s]^\beta e^{-\xi^s} (k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{p} \right] + \\ & + I[\xi^{(s-p)}; \beta] (k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{2p} \right] \left( s - \frac{\beta}{\xi} \right) - \\ & - I[\xi^s; \beta] (k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{p} \right] \left( s - \frac{\beta}{\xi} \right) + I[\xi^p; \beta] \frac{s}{2p} (k-1) \quad (94) \end{aligned}$$

Notăm cu:

$$\begin{aligned} A &= \frac{1}{\Gamma(\beta)} \frac{1}{\xi} [\xi^{(s-p)}]^\beta e^{-\xi^{(s-p)}} \\ B &= \frac{1}{\Gamma(\beta)} \frac{1}{\xi} [\xi^s]^\beta e^{-\xi^s} \\ C &= I[\xi^{(s-p)}; \beta] \\ D &= I[\xi^s; \beta] \\ E &= I[\xi^p; \beta] \end{aligned} \quad (95)$$

Cu notațiile (95) expresia (94) devine:

$$\begin{aligned} \text{DIF} = & A(k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{2p} \right] - B(k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{p} \right] + \\ & + C(k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{2p} \right] \left( s - \frac{\beta}{\xi} \right) - D(k-1) \left[ ks \frac{\xi-1}{p^2} + \frac{1}{p} \right] \left( s - \frac{\beta}{\xi} \right) + \\ & + E \frac{s}{2p} (k-1) \end{aligned}$$

Sau, organizând în partea dreaptă:

$$DIF = \frac{k-1}{2P} \left[ A - 2B + \left(s - \frac{\beta}{\xi}\right)(C - 2D) + E \cdot s \right] - (k-1)ks \frac{\xi-1}{p^2} \left[ -A + B + \left(s - \frac{\beta}{\xi}\right)(-C + D) \right] \quad (96)$$

Expresia relativ simplă (96) obținută pentru valoarea DIF va fi cercetată în continuare pentru precizarea posibilităților de apariție a anomaliei dimensiunii de pagină.

În cele ce urmează ne vom limita la cazul în care  $s > \frac{\beta}{\xi}$  adică dimensiunea memoriei reale alocate pentru rularea programului este mai mare decât lungimea medie a ciclurilor din program. Este o limitare firească, ce decurge din practica curentă a sistemelor cu memorii virtuale, în care, pentru a menține activitatea de paginare în limite moderate, un program este eligibil de a fi rulat numai în momentul în care există posibilitatea de a i se aloca suficient spațiu de memorie reală. În cazul nostru această "suficiență" este caracterizată de lungimea medie a ciclurilor programului în discuție. O discuție mai în detaliu a acestor probleme a fost făcută în cap.2 secțiunea 6.1.1. relativă la sistemele cu memorie virtuală paginată și factorii ce afectează performanța unui asemenea sistem.

Pentru stabilirea valorilor mărimilor A și B cercetăm variația funcției:

$$f(x) = \frac{1}{\Gamma(\beta)} \frac{1}{\xi} x^{\beta} e^{-x}$$

Prima derivată a acestei funcții:

$$f'(x) = \frac{1}{\Gamma(\beta)} \frac{1}{\xi} x^{\beta-1} e^{-x} (\beta - x)$$

se anulează în punctul  $x = \beta$ , punct de maxim pentru  $f(x)$ .

Intrucât:

$$A = f\left[\xi\left(s - \frac{\beta}{\xi}\right)\right];$$

$$B = f[\xi s]$$

iar ambele argumente fiind mai mari ca  $\beta$  ( $\xi s > \beta$  sau  $s > \frac{\beta}{\xi}$ , condiție îndeplinită în situația în care ne aflăm), rezultă că

$$1 > A > B$$

De asemenea, conform celor arătate în cap.4,

$$C < D < E < 1$$

Inegalitățile rezultă din relația de definiție a funcției  $f$  incomplete și a valorii  $\beta$

$$\beta > 1$$

Expresia (96) se mai poate scrie:

$$\begin{aligned} \text{DIF} = & \frac{k-1}{2P} \left[ A - 2B + \frac{\beta}{\zeta} (2D-C) + s(C - 2D + E) \right] - \\ & - (k-1) ks \frac{\zeta-1}{p^2} \left[ -A + B + (s - \frac{\beta}{\zeta})(-C + D) \right] \end{aligned} \quad (97)$$

Notînd cu:

$$\begin{aligned} \lambda_1 = & \frac{k-1}{2P} \left[ A - 2B + \frac{\beta}{\zeta} (2D - C) + s(C - 2D + E) \right] \\ \lambda_2 = & (k-1) ks \frac{1}{p^2} \left[ -A+B+(s - \frac{\beta}{\zeta})(-C+D) \right] \end{aligned} \quad (98)$$

și ținînd seama că, conform celor arătate

$$\begin{aligned} \lambda_1 &> 0 \\ \lambda_2 &> 0 \end{aligned}$$

expresia DIF devine:

$$\text{DIF} = \lambda_1 - (\zeta-1)\lambda_2 \quad (99)$$

Ea atinge valori pozitive (ueci are loc situația de anomalie a dimensiunii de pagină) în cazul în care:

$$\zeta < \frac{\lambda_1}{\lambda_2} + 1 \quad (100)$$

Valoarea maximă pozitivă a DIF este atinsă în situația în care  $\zeta = 1$ .

Rezultatul obținut arată că apariția situației de anomalie a dimensiunii de pagină este posibilă în cazul acelor programe sau secțiuni de program cu valori foarte mici ale parametrului  $\zeta$ , ce satisfac (100).

Pentru a interpreta sensul rezultatului analitic obținut vom cerceta mai în detaliu comportarea localizată a unui program.

## 2. Comportarea localizată a unui program.

### 2.1. Definiție și justificare.

În decursul întregii lucrări am presupus că localizarea este o proprietate fundamentală a comportării de acces a unui program. Localizarea este proprietatea ca, în decursul oricărui interval de execuție, programul va favoriza unele din paginile

lui într-o măsură mai mare decât pe altele; în decursul unor intervale distincte de execuție grupul de pagini favorizate poate fi diferit. Cu alte cuvinte, observând mostrele de referire la adresele logice ale unui program într-un interval oarecare de timp se poate constata că programul nu-și distribuie referirile în mod uniform în întreg spațiu al adreselor. Există cel puțin cinci factori ce motivează această presupunere:

1. fluxuri de instrucții secvențiale.

Atât programatorii, cât și compilatoarele manifestă tendința să organizeze în mod secvențial instrucțiile ce direcționează activitatea unui program; acest lucru este în special valabil în cazul calculatoarelor cu instrucții cu o singură adresă. Dacă un program aduce o instrucție dintr-o pagină dată, este foarte probabil ca el să aducă în continuare instrucția imediat următoare, din aceeași pagină.

2. modularitatea funcțională.

Modulele de program sînt frecvent organizate și executate printr-o funcție.

3. organizarea datelor înrudite după conținut.

Informațiile sînt în mod obișnuit grupate după conținut în segmente și sînt în mod normal referite pe această cale. Astfel, referirile programului în spațiul adreselor vor apărea sub formă de pachete, un pachet de referiri corespunzînd domeniului din spațiul adreselor ce conține informații înrudite după conținut.

4. ciclurile.

Programele prezintă frecvent cicluri, ce se pot extinde asupra unui grup de pagini.

5. modul de programare.

Dîndu-și seama că programele pe care le scriu vor rula într-un mediu virtual și că transferurile de pagini sînt costisitoare, programatorii își organizează algoritmi lor astfel încît activitatea programului să fie localizată în cadrul unor submulțimi ale informațiilor. Acest aspect a fost tratat mai extins la cap.2, în secțiunea 6.1.1.2. relativă la căile de îmbunătățire a performanței sistemului într-un mediu cu memorie virtuală.

Observațiile experimentale confirmă că presupunerea privind comportarea localizată a mostrei de referiri a unui program este corectă.

Presupunem, în cazul contrar, că, în timpul fiecărui interval de timp virtual, programul își distribuie referirile lui la spațiul adreselor în mod uniform. Presupunem că o fracțiune  $s$  ( $0 \leq s \leq 1$ ) a paginilor lui a fost dispusă în memoria principală. Fie  $\mu(s)$  fracțiunea din referirile programului, ce se fac asupra grupului de pagini ce nu sînt plasate în memorie; deoarece referirile sînt distribuite uniform, rezultă că:

$$\mu(s) = 1 - s$$

Funcția  $\mu(s)$  determinată experimental (18,359) și ilustrată în fig.35 contrazice ipoteza făcută. S-a stabilit că în realitate  $\mu(s)$  se poate reprezenta printr-o curbă, situată sub graficul  $\mu(s) = 1 - s$ .




Fig.35. Funcția  $\mu(s)$

A fost observat că există un număr  $s_0$  și o constantă  $k > 1$ , astfel că, dacă  $s \leq s_0$ , atunci:

$$\mu(s) = 1 - ks$$

adică programul își distribuie referirile lui în mod uniform numai asupra unui subgrup al informațiilor lui. Numerele  $s_0$  și  $k$  depind de programul particular și de algoritmul concret de decizie utilizat pentru a stabili ce informații trebuie să stea în memoria principală.

Pe baza celor arătate mai sus se poate aprecia că localizarea este o proprietate a comportării de acces a programului.



## 2.2. Tipuri de localizare a comportării de acces a programului.

Se pot evidenția două forme extreme ale comportării localizate a unui program în privința modului cum face referiri la spațiul adreselor: localizare temporală și localizare spațială.

### (a) localizare temporală.

Dacă adresele logice ( $a_1, a_2, \dots$ ) sînt referite în decursul intervalului de timp  $(t-T, t)$  atunci există o probabilitate mare ca aceleași adrese logice să fie referite în decursul intervalului  $(t, t+T)$ . Această comportare poate fi explicată prin construcții de program precum cicluri, variabile frecvent utilizate și subrutine frecvent utilizate;

### (b) localizare spațială.

Dacă adresa logică  $a$  este referită la momentul  $t$ , atunci există o probabilitate mare ca o adresă logică în domeniul  $(a-A, a+A)$  să fie referită la momentul  $t+1$ . Această comportare poate fi explicată prin construcții de program, precum o ordonare secvențială a instrucțiilor și structuri lineare de date (ex. matricii).

Aceste două tipuri de comportare localizată a programelor - temporală și spațială - sînt aspectele de bază, de extremă, ce se pot remarca în modul cum își distribuie un program referirile la spațiul adreselor. Aceste concepte se pot îmbina pentru a defini localizarea unui program la modul general, spațio-temporal, în modul următor:

Dacă adresele logice ( $a_1, a_2, \dots$ ) sînt referite în decursul intervalului de timp  $(t-T, t)$ , atunci există o probabilitate mare ca adresele logice din domeniile  $[(a_1-A, a_1+A), (a_2-A, a_2+A) \dots]$  să fie referite în decursul intervalului de timp  $(t, t+T)$ .

## 2.3. Localizarea și algoritmi de înlocuire.

Putem începe a înțelege factorii ce cauzează anomalia dimensiunii de pagină prin studierea modului cum diferiți algoritmi de înlocuire convenționali (vezi secțiunea 3.4 a cap.2) tratează localizarea temporală și spațială.

Astfel putem constata că, în timp ce măsurilor ce vîncă localizarea temporală a programelor li se acordă o atenție explicită, măsurile ce se referă la localizarea spațială sînt de obicei

tratate implicit. De exemplu, algoritmul LRU (cel mai puțin recent utilizat) se preocupă foarte mult de aspectele temporale ale mostrei de referiri a programului la spațiul adreselor. Aspectele spațiale sînt tratate ca un produs secundar, prin faptul că algoritmul de înlocuire aduce în memoria principală, la un moment dat, o pagină întreagă (adică o regiune spațială), iar deciziile de înlocuire LRU sînt bazate pe utilizarea acestor pagini.

Tinînd seama de acest mod în care sînt luate în considerație localizarea temporală și spațială a programelor de către algoritmi de înlocuire uzuali, se poate face următoarea observație.

Micșorarea dimensiunii de pagină conduce la creșterea performanței (mărirea valorii proporției succeselor) algoritmilor de înlocuire în cazul unui program caracterizat printr-o comportare localizată pronunțat temporală și la scăderea performanței (micșorarea valorii proporției succeselor) în cazul unui program caracterizat printr-o comportare localizată pronunțat spațială. Acest lucru este o urmare a faptului că, prin micșorarea dimensiunii de pagină (în cadrul unei alocări date în  $M_1$ ), în nivelul  $M_1$  al ILVI se va realiza o colecție mai variată de porțiuni de program, deși fiecare din ele mai mică ca dimensiune. Acest tip de colecție poate favoriza un program cu referiri dispersate și grupate la spațiul adreselor, ca urmare a unui caracter temporal al comportării sale de acces. Pe de altă parte însă, micșorarea dimensiunii de pagină defavorizează un program ce are o comportare de localizare spațială în modul de a-și referi adresele, căci prin micșorarea dimensiunii paginii se micșorează și numărul de adrese ce pot fi referite succesiv în cadrul aceleiași pagini.

Este de dorit ca algoritmi de înlocuire utilizați să ia în considerație ambele localizări - temporală și spațială.

Modul în care un program sau o secțiune a unui program își distribuie referirile la spațiul de adrese poate fi caracterizat prin următoarea matrice a localizărilor 2 x 2:

		Localizare temporală	
		slabă	pronunțată
Localizare	slabă	1	2
spațială	pronunțată	3	4

Domeniul 1 caracterizat printr-o slabă localizare temporală și slabă localizare spațială este în mod evident nedorit ca situație într-un mediu cu memorii virtuale. După cum s-a arătat în secțiunea 6.1.1.2. a cap.2 există numeroși algoritmi și tehnici pentru a îmbunătăți slaba comportare de localizare a programelor. Domeniul 4 caracterizat printr-o pronunțată localizare spațială și pronunțată localizare temporală este domeniul cu performanțele cele mai bune și reprezintă scopul unei bune proiectări de program. Nu este însă totdeauna posibil sau convenabil a proiecta programe care ating caracteristici pronunțate atât de localizare temporală cât și de localizare spațială. Astrei, există multe programe operând în domeniile 2 și 3.

În consecință, tehnicile de gestiune a ierarhiilor de memorii necesită algoritmi ce să prevadă o mai mare flexibilitate și robustețe pentru a ține seama de sensibilitatea sistemului în privința localizării temporale și spațiale. Acești algoritmi trebuie să ia în considerare în mod explicit localizarea spațială a unui program.

### 3. Interpretare cu caracter general a anomaliilor dimensiunii de pagină.

În secțiunea 1 a acestui capitol s-a ajuns la rezultatul, conform căruia apariția situației de anomalie a dimensiunii de pagină este posibilă în cazul acelor programe sau secțiuni de program cu valori mici ale parametrului  $\sigma$ , ce satisfac (100). Parametrul  $\sigma$  reprezintă în cadrul modelului propus al comportării de acces a programului, numărul de ori de care este executat un ciclu cu lungimea  $\alpha$ . O valoare mică a acestui parametru (deci apropiată de 1) este indicele unei slabe localizări temporale a programului sau secțiunii de program respective, conform determinării localizării temporale date în secțiunea 2.2 a acestui capitol.

În cazul limită, în care anomalia de pagină apare în modul cel mai pronunțat (analitic vorbind, DIF din expresia (99) atinge o valoare maximă) valoarea lui  $\sigma$  este

$\sigma = 1$ , deci nu există cicluri în cadrul acelei secțiuni de program, instrucțiunile executându-se strict secvențial. Este evident cazul unei localizări spațiale pronunțate a modului în care programul, în cadrul secțiunii lui respective, își distribuie referirile la spațiul adreselor.

În consecință, anomalia dimensiunii de pagină poate apărea în cadrul unui program operând într-un domeniu caracterizat printr-o pronunțată localizare spațială și o slabă localizare temporală (domeniul 3 în matricea localizărilor). Ea nu este o funcție strictă de dimensiunea de pagină, ci este o consecință a modului în care programul își distribuie referirile lui la spațiul adreselor și anume a proprietăților de localizare spațială și temporală ale programului.

## CAP.6. PREVENIREA APARIȚIEI ANOMALIEI DIMENSIUNII DE PAGINĂ

Cercetarea anomaliei dimensiunii de pagină, efectuată în cap.5., a evidențiat faptul că apariția acestei situații în cadrul unui sistem ierarhic de memorii este o consecință a comportării de acces localizate, pronunțat spațială și slab temporală, a programului. Această comportare localizată este însă o caracteristică globală, la nivel macroscopic, a modului cum programul își distribuie referirile la spațiul adreselor.

Pentru a putea elabora măsuri care să conducă la posibilitatea prevenirii apariției acestei anomalii este necesară o cercetare mai detaliată a mecanismului prin care modul în care sînt făcute referirile programului în spațiul adreselor conduce la apariția anomaliei. Această analiză la nivel microscopic a comportării de acces a programului se referă la cercetarea șirului de referiri de pagină.

### 1. Cercetarea șirului de referiri de pagină.

Fie un sistem ierarhic de memorii cu două nivele, în cadrul căruia utilizăm succesiv pagini cu dimensiunea de  $p$  și respectiv  $\frac{p}{2}$  octeți. Comportamentul de acces al programului la spațiul adreselor este caracterizat prin cele două șiruri de referiri de pagină  $X_p$  și  $X_{\frac{p}{2}}$ .

Fie un moment oarecare  $t_1$  la care are loc referirea la adresa logică  $a$ , ce corespunde referirii la pagina  $A$  (în cadrul șirului de referiri de pagină  $X_p$ ) și - respectiv - referirii la pagina  $A_1$  (în cadrul șirului de referiri de pagină  $X_{\frac{p}{2}}$ ).  $A_1$  și  $A_2$  sînt cele două pagini de dimensiune  $\frac{p}{2}$  octeți ce alcătuiesc pagina  $A$  cu dimensiunea  $p$  octeți.

Ca și în cadrul cap.3, secțiunea 2,  $e_p$  și  $e_{\frac{p}{2}}$  reprezintă numărul defectelor de pagină obținute în cadrul dimensiunii de pagină  $p$  și respectiv  $\frac{p}{2}$ , iar  $\xi$  este raportul acestor două numere:

$$\xi = \frac{e_{\frac{p}{2}}}{e_p}$$

În tratarea referirii la adresa logică  $a$  și a utilizării

celor două dimensiuni de pagină pot apărea următoarele 4 cazuri, indicate în tabelul 6 și care sînt dependente de faptul dacă pagina referită A (în cazul utilizării dimensiunii p) sau  $A_1$  (în cazul utilizării dimensiunii  $\frac{p}{2}$ ) se găsesc sau nu în nivelul  $L_1$  al ierarhiei de memorii.

Tabelul 6

Cazul	pagina A se găsește în $L_1$	pagina $A_1$ se găsește în $L_1$	$\Delta e_p$	$\Delta e_{\frac{p}{2}}$	$\Delta e_{\frac{p}{2}} - \Delta e_p$	Efect
1	da	da	0	0	0	$\xi \rightarrow 1$
2	da	nu	0	1	1	$\xi \rightarrow > 1$
3	nu	da	1	0	-1	$\xi \rightarrow < 1$
4	nu	nu	1	1	0	$\xi \rightarrow 1$

În cazurile 1 și 4 se constată situații asemănătoare în cadrul utilizării celor două dimensiuni de pagină (în cazul 1 nu este necesară aducerea unei pagini, iar în cazul 4 este necesară aducerea unei pagini noi, deci are loc un defect de pagină); apariția acestor situații determină pe  $\xi$  să tindă spre 1.

În cazul 3, în cadrul utilizării dimensiunii de pagină p are loc un defect de pagină, iar în cadrul utilizării dimensiunii de pagină  $\frac{p}{2}$  nu este cerută o pagină nouă; această situație, dacă apare frecvent, va cauza ca  $\xi$  să fie mai mic ca 1. Acesta este rezultatul dorit prin reducerea dimensiunii de pagină.

Numai cazul 2, în care prin utilizarea dimensiunii de pagină  $\frac{p}{2}$  are loc un defect de pagină, în timp ce prin utilizarea dimensiunii de pagină p nu este cerută o pagină nouă, contribuie la creșterea raportului  $\xi$ .

Astfel, în scopul urmărit de noi, vom analiza mai amănunțit această ultimă situație.

Situația în discuție implică faptul că pagina A să existe în memorie la momentul  $t_1$ . De aici rezultă că această

pagină a fost adusă în  $M_1$  printr-o referire anterioară. Prin cercetarea în sens invers a șirului de referiri de pagină  $X_p$  se poate identifica momentul  $t_j$  în care a avut loc referirea ce a condus la aducerea paginii  $A$  în  $M_1$ .

La momentul  $t_j$  a avut loc o referire și în cazul șirului  $X_{\frac{p}{2}}$ , fie la  $A_1$ , fie la  $A_2$ . Vom considera separat aceste două cazuri.

$$\begin{aligned} \text{Cazul 1: } t &= \dots, t_j, \dots, t_i, \dots \\ X_p &= \dots, A, \dots, A, \dots \\ X_{\frac{p}{2}} &= \dots, A_2, \dots, A_1, \dots \end{aligned}$$

În acest caz, la momentul  $t_j$ , în cazul utilizării dimensiunii de pagină  $\frac{p}{2}$ , a fost referită pagina  $A_2$ . Astfel, pentru a aduce în  $M_1$  același volum de informații (p octeți) în cazul utilizării dimensiunii de pagină de  $\frac{p}{2}$  pot fi necesare două aduceri de pagină, față de una singură necesară în cazul utilizării dimensiunii de pagină  $p$ . Prin situații ce se caracterizează prin aceste șiruri de referiri  $\xi$  nu ar putea depăși valoarea 2.

$$\begin{aligned} \text{Cazul 2: } t &= \dots, t_j, \dots, t_i, \dots \\ X_p &= \dots, A, \dots, A, \dots \\ X_{\frac{p}{2}} &= \dots, A_1, \dots, A_1, \dots \end{aligned}$$

În acest caz, urmare a referirii din momentul  $t_j$ , pagina  $A$  (în cadrul utilizării dimensiunii  $p$ ) și pagina  $A_1$  (în cadrul utilizării dimensiunii  $\frac{p}{2}$ ) se găsesc în  $M_1$  din acest moment. Totuși în momentul  $t_i$  pagina  $A$  se mai găsește în  $M_1$ , în timp ce pagina  $A_1$  nu mai este. În aceste circumstanțe,  $\xi$  poate depăși valoarea 2. De exemplu imaginînd că următoarea referire de pagină ar fi  $A_2$ , vom avea o situație în care au loc 3 aduceri de pagină în cazul utilizării dimensiunii  $\frac{p}{2}$ , față de o singură aducere de pagină în cazul utilizării dimensiunii  $p$ . Mai mult chiar, este posibil ca referirile situate între  $t_j$  și  $t_i$  să fie repetate: acest lucru ar conduce la aducerea continuă a paginii  $A_1$  în cazul unei dimensiuni de pagină  $\frac{p}{2}$ , fără nici o aducere corespunzătoare în cazul celeilalte dimensiuni de pagină.

Acest caz apare numai în situația în care între momentele  $t_j$  și  $t_i$ , pagina  $A_1$  (în cazul utilizării dimensiunii de pagină  $\frac{p}{2}$ ), a fost înlocuită din  $M_1$ , în timp ce pagina  $A$  (în cazul utilizării

dimensiunii de pagină  $p$ ) rămînc în  $M_1$ . Cu alte cuvînte, această situație poate apărea numai dacă la un anumit moment  $t$ , pagina  $A_1$  sau  $A_2$  (în cazul dimensiunii de pagină  $\frac{p}{2}$ ) este selectată pentru a fi înlocuită din  $M_1$ , în timp ce pagina corespunzătoare  $A$  (în cazul dimensiunii de pagină  $p$ ) nu este înlocuită din  $M_1$ .

## 2. Modificarea algoritmilor de înlocuire uzuali pentru prevenirea apariției anomaliei dimensiunii de pagină.

Pe baza identificării situațiilor ce conduc la apariția anomaliei dimensiunii de pagină, identificare realizată în secțiunea precedentă, se poate propune o procedură ce conduce la posibilitatea prevenirii apariției acestei anomalii. Această procedură simplă constă în următoarele:

În primul rînd - paginile programului în cauză se organizează în grupe, mărimea cărora corespunde unei dimensiuni mărite de pagină (după numărul de pagini din grupă). O asemenea grupă o vom numi pagină-martor. Într-un caz frecvent întîlnit în cele ce urmează, două pagini consecutive ale programului inițial sînt considerate ca alcătuint o grupă. Dimensiunea acestor pagini-martor corespunde utilizării unei dimensiuni duble de pagină.

În al doilea rînd - algoritmi de înlocuire uzuali vor fi aplicați la ansamblul paginilor unei grupe (cu alte cuvînte aceste pagini sînt cuplate în privința deciziilor de ordonare), astfel ca o pagină oarecare din cadrul unei grupe nu poate să fie niciodată înlocuită din  $M_1$ , dacă pagina-martor corespunzătoare nu ar fi fost de asemenea înlocuită din  $M_1$ .

În termenii secțiunii precedente este împiedicată o situație în care o pagină a programului  $A_1$  sau  $A_2$  (ce formează împreună o grupă) să fie scoasă din  $M_1$ , în timp ce pagina-martor corespunzătoare  $A$  nu este scoasă din  $M_1$ .

În acest mod se evită posibilitatea apariției unei situații, caracterizată ca reprezentînd cazul 2 în tabelul 6 și, conform celor expuse în secțiunea precedentă, se evită astfel posibilitatea ca raportul  $\xi$  să poată depăși va-



loarea 2. Astfel, se previne posibilitatea apariției anomaliilor dimensiunii de pagină.

Modul de aplicare al acestei proceduri este exemplificat în continuare în cazul utilizării unor algoritmi de înlocuire cunoscuți, dar modificați conform procedurii descrise.

### 3. Exemple de utilizare a unor algoritmi de înlocuire modificați.

Vom arăta în continuare modul în care se aplică procedura descrisă, în cadrul algoritmilor LRU și FIFO modificați.

#### 3.1. Algoritm LRU modificat.

În fig.36 este cercetat un șir de referiri de pagină, în cazul utilizării unor pagini de dimensiunea  $p$  și respectiv  $\frac{p}{2}$  oceteți și folosirea ca algoritm de înlocuire atât a LRU, cât și LRU modificat.


Parametrii sistemului, în cazul utilizării paginii  $p$

- $X_p = A, B, A, B, C, C, B, A, A, C, C$
- $\lambda = 11$
- $\gamma = \{A, B, C\}$
- $\eta = 3$
- $m_1 = 2$
- algoritm de înlocuire LRU

Parametrii sistemului, în cazul utilizării paginii  $\frac{p}{2}$

- $X_{\frac{p}{2}} = A_1, B_1, A_2, B_2, C_1, C_2, B_1, A_1, A_2, C_1, C_2$
- $\lambda = 11$
- $\gamma = \{A_1, A_2, B_1, B_2, C_1, C_2\}$
- $\eta = 6$
- $m_1 = 4$
- algoritm de înlocuire - LRU  
- LRU modificat

./.



Succesiunea referirilor		1	2	3	4	5	6	7	8	9	10	11
Pagina p	Sirul de referiri	A	B	A	B	C	C	B	A	A	C	C
	Defecte de pagina	*	*			*			*		*	
	Conținutul lui $M_1$	1 A	B	A	B	C	C	B	A	A	C	C
Algo- ritm LRU	Sirul de referiri	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$
	Defecte de pagina	*	*	*	*	*	*	*	*	*	*	*
	Conținutul lui $M_1$	1 $A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$
		2	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$
		3		$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$
Pagina $\frac{p}{2}$	Sirul de referiri	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$
	Defecte de pagina	*	*	*	*	*	*	*	*	*	*	*
	Conținutul lui $M_1$	1 $A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$
Algoritm LRU modi- ficat		2	$A_1$	$A_1$	$B_1$	$B_2$	$C_1$	$B_2$	$B_1$	$A_1$	$A_2$	$C_1$
		3		$B_1$	$A_2$	$B_1$	$B_2$	$C_2$	$B_2$	$B_1$	$A_1$	$A_2$
		4			$A_1$	$A_2$	$B_1$	$C_1$	$C_2$	$B_2$	$B_1$	$A_1$

Rezultate:

- algoritm LRU -  $e_p = 5$
- $e_{\frac{p}{2}} = 11$
- $\xi = \frac{11}{5} = 2,2$
- algoritm LRU modificat:
- $e_p = 5$
- $e_{\frac{p}{2}} = 10$
- $\xi = \frac{10}{5} = 2$

Fig.36. Exemplu de utilizare a algoritmului LRU modificat.

Din fig.36 rezultă că prin aplicarea algoritmului LRU modificat, raportul  $\xi$  a fost limitat la valoarea 2, deși el atinge valoarea 2,2 în cazul utilizării unui algoritm de înlocuire LRU normal. Din figură rezultă de asemenea, modul cum procedura descrisă în secțiunea 2 precedentă afectează algoritmul de înlocuire. Astfel, se pot observa diferențe

între conținuturile lui  $M_1$  în cazul aplicării algoritmului LRU și în cazul aplicării algoritmului LRU modificat.

Pentru scopuri de referire, în fig.36 fiecare stare a conținutului  $M_1$  este identificată cu numere de la 1 la 11.

În implementarea descrisă a algoritmului LRU modificat ori de câte ori ambele pagini ce alcătuiesc o grupă se găsesc în  $M_1$  ele sînt întotdeauna învecinate în ordonarea realizată în  $M_1$ .

Astfel, la pasul 3 al șirului de referiri de pagină se poate constata prima deosebire între modul de aplicare al algoritmului LRU și al celui LRU modificat. Pagina  $A_2$  este referită în acest pas și este adusă în  $M_1$ . În cazul utilizării algoritmului LRU,  $A_2$  este plasată în fruntea ordonării paginilor din  $M_1$ , ordonare care devine  $A_2, B_1, A_1$ . Pe de altă parte, în cazul utilizării algoritmului LRU modificat, la pasul 3 este observat că pagina  $A_1$  a fost deja adusă în  $M_1$ . Astfel, în momentul în care pagina  $A_2$  este plasată în fruntea ordonării paginilor din  $M_1$ ,  $A_1$  este cuplat cu  $A_2$ , rezultînd ordonarea  $A_2, A_1, B_1$ .

La pasul 7 al șirului de referiri de pagină se constată un alt aspect de interes al modelului cum acționează algoritmul LRU modificat. La pasul precedent ordonarea paginilor în  $M_1$  a fost  $C_2 C_1 B_2 B_1$ .

Cînd se face referirea la  $B_1$ , în pasul 7, nu există necesitatea de a iniția o aducere de pagină, deoarece  $B_1$  este deja în  $M_1$ . Ordonarea paginilor din  $M_1$  devine:  $B_1 B_2 C_2 C_1$ , căci algoritmul LRU impune ca referirea cea mai recentă  $B_1$  să fie plasată în fruntea ordonării. Însă modul cum a fost modificat acest algoritm a determinat ca pagina  $B_2$  să fie de asemenea deplasată spre fruntea ordonării, pentru a continua să fie învecinată, în cadrul ordonării din  $M_1$ , cu  $B_1$ .

Există diferite moduri în care poate fi realizat dezideratul ca decizia de înlocuire a paginilor să fie luată pe baza considerării ansamblului paginilor unei grupe. În algoritmul LRU modificat descris mai sus, ori de câte ori toate paginile ce formează o grupă se găsesc în  $M_1$ , ele sînt rearanjate, în ordonarea paginilor din  $M_1$ , astfel ca să fie învecinate.

Condiția ca o pagină a unei grupe să nu poată fi înlocuit din  $M_1$ , dacă pagina martor corespunzătoare nu a fost și ea înlo-

cuită din  $M_1$ , poate fi realizată în diferite moduri. Astfel, șirul de înlocuire LRU poate fi lăsat în ordonarea lui normală, conformă aplicării unui algoritm LRU obișnuit, însă la apariția necesității de a înlocui o pagină din  $M_1$  trebuie construit un algoritm care să cerceteze șirul LRU și să selecteze pagina cerută pentru înlocuire, pe baza considerării ansamblului paginilor din grupe.

### 3.2. Algoritm FIFO modificat.

În fig. 37 este cercetat un șir de referiri de pagină, în cazul utilizării unor pagini de dimensiunea de  $p$  și respectiv  $\frac{p}{2}$  octeți și folosirea ca algoritm de înlocuire atât a FIFO, cât și FIFO modificat.

Parametrii sistemului, în cazul utilizării paginii  $p$ :

- $X_p = A, B, A, B, C, C, B, A, A, C, C$
- $\lambda = 11$
- $\gamma = \{A, B, C\}$
- $\eta = 3$
- $m_1 = 2$
- algoritm de înlocuire FIFO

Parametrii sistemului, în cazul utilizării paginii  $\frac{p}{2}$ :

- $X_{\frac{p}{2}} = A_1, B_1, A_2, B_2, C_1, C_2, B_1, A_1, A_2, C_1, C_2$
- $\lambda = 11$
- $\gamma = \{A_1, A_2, B_1, B_2, C_1, C_2\}$
- $\eta = 6$
- $m_1 = 4$
- algoritm de înlocuire - FIFO  
- FIFO modificat

Succesiunea referirilor		1	2	3	4	5	6	7	8	9	10	11	
Pagina p	Sirul de referiri	A	B	A	B	C	C	B	A	A	C	C	
	Defecte de pagina	=	*			*			=				
	Conținutul lui	1	A	B	B	C	C	C	A	A	A	A	
	$M_1$	2	A	A	A	B	B	B	C	C	C	C	
Algo- ritm FIFO	Sirul de referiri	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$	
	Defecte de pagina	=	=	=	=	=	=	=	=	=	=	=	
	Conținutul lui	1	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$
		2		$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$
		3			$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$
	4				$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	
Pagina p 2	Sirul de referiri	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$B_1$	$A_1$	$A_2$	$C_1$	$C_2$	
	Defecte de pagina	=	=	*	*	*	*		=	=			
	Conținutul lui	1	$A_1$	$B_1$	$A_2$	$B_2$	$C_1$	$C_2$	$C_2$	$A_1$	$A_2$	$A_2$	$A_2$
Algoritm FIFO modificat	$M_1$	2		$A_1$	$A_1$	$B_1$	$B_2$	$C_1$	$C_1$	$C_2$	$A_1$	$A_1$	$A_1$
		3			$B_1$	$A_2$	$B_1$	$B_2$	$B_2$	$C_1$	$C_2$	$C_2$	$C_2$
		4				$A_1$	$A_2$	$B_1$	$B_1$	$B_2$	$C_1$	$C_1$	$C_1$

Rezultate:

- . algoritm FIFO -  $e_p = 4$
- $e_p = 11$
- $\rho = \frac{11}{4} = 2,75$

- . algoritm FIFO modificat
- $e_p = 4$
- $e_p = 8$
- $\rho = \frac{8}{4} = 2$

Fig.37. Exemplu de utilizare a algoritmului FIFO modificat.

Din fig.37 se observă că prin utilizarea algoritmului FIFO modificat, raportul  $\rho$  a fost limitat la valoarea 2, deși el atinge valoarea 2,75 în cazul utilizării unui algoritm de înlocuire FIFO normal.

Exemplul din fig.37 ilustrează complet toate aspectele importante implicate de utilizarea algoritmului FIFO modificat asupra ordonării paginilor. În particular, presupunem de exemplu că pagina  $A_1$  este referită în cadrul unui șir de referiri de pagină și, întrucât nu se găsește în  $M_1$ , trebuie adusă. Ordinea paginilor conținute în  $M_1$  se modifică după cum urmează:

1. Dacă pagina  $A_2$  nu este conținută în  $M_1$ , atunci pagina  $A_1$  este plasată în fruntea ordonării FIFO.

2. Dacă pagina  $A_2$  este conținută în  $M_1$ , atunci pagina  $A_1$  este plasată imediat înaintea paginii  $A_2$  în ordonarea FIFO. Ordonarea relativă a paginii  $A_2$  rămâne nemodificată.

Lotivul ce stă la baza părții a doua a acestei proceduri decurge din regula de ordonare FIFO normală, care plasează o pagină  $A$  în fruntea ordonării numai dacă ea nu era deja conținută în  $M_1$ . Dacă ea se afla deja în  $M_1$ , ea rămâne la poziția ei anterioară de ordonare. Pe de altă parte în cadrul unui algoritm modificat pe baza procedurii descrise în secțiunea 2 decizia de înlocuire a paginilor se ia pe baza considerării ambelor pagini ( $A_1, A_2$ ) ale unei grupe.

#### 4. Eficiența algoritmilor modificați.

Procedura propusă de modificare a algoritmilor de înlocuire uzuali are în mod evident o influență asupra eficienței generale a algoritmului de bază de înlocuire ce este utilizat.

Putem considera că comportarea de acces a unui program în spațiul adreselor, în timpul unei activități de scurtă durată, poate fi caracterizată prin trei regiuni, delimitate de valoarea raportului  $\rho$  al numerelor defectelor de pagină obținute în cadrul utilizării dimensiunilor de pagină de  $p$  și  $\frac{p}{2}$  și în presupunerea că nu este utilizată procedura propusă de modificare a algoritmului de înlocuire.

1. referire rară -  $\rho$  mic ( $\rho < 1$ )
2. referire moderată -  $\rho$  moderat ( $1 < \rho < 2$ )
3. referire densă -  $\rho$  mare ( $\rho > 2$ )

În regiunea de referire rară, este puțin probabil ca ambele jumătăți  $A_1$  și  $A_2$  ale unei pagini martor  $A$  să se găsească în  $M_1$  simultan: ca atare procedura propusă de modi-

ficare a algoritmului de înlocuire va avea un efect minim asupra performanței.

În regiunea de referire moderată, algoritmul de înlocuire modificat acționează aproape la fel de eficient ca și algoritmul de înlocuire nemodificat. Astfel, pe baza considerării fig.38, unde este analizat modul de comportare al algoritmului de înlocuire LRU și al celui LRU modificat asupra unui șir de referiri de pagină, se poate constata că utilizarea algoritmului de înlocuire LRU modificat nu numai că menține raportul  $\xi$  al numerelor defec-telor de pagină mic, dar, în cazul considerat, conduce chiar la micșorarea lui.

Parametrii sistemului, în cazul utilizării dimensiunii  $p$  de pagină:

- $X_p = A, B, A, C, B, C, A, B, C, B, C$
- $\lambda = 11$
- $\gamma = \{A, B, C\}$
- $\eta = 3$
- $m_1 = 2$
- algoritm de înlocuire LRU

Parametrii sistemului, în cazul utilizării dimensiunii  $\frac{p}{2}$  de pagină:

- $X_{\frac{p}{2}} = A_1, B_1, A_2, C_1, B_2, C_2, A_2, B_1, C_1, B_2, C_2$
- $\lambda = 11$
- $\gamma = \{A_1, A_2, B_1, B_2, C_1, C_2\}$
- $\eta = 6$
- $m_1 = 4$
- algoritm de înlocuire - LRU  
- LRU modificat

Succesiunea referirilor		1	2	3	4	5	6	7	8	9	10	11	
Pagina p	Sirul de referiri	A	B	A	C	B	C	A	C	C	B	C	
	Defecte de pagina	#	#		#	#		#	#	#			
	Conținutul lui $M_1$	1	A	B	A	C	B	C	A	B	C	C	
Algo- ritm LRU	Sirul de referiri	$A_1$	$B_1$	$A_2$	$C_1$	$B_2$	$C_2$	$A_2$	$B_1$	$C_1$	$B_2$	$C_2$	
	Defecte de pagina	#	#	#	#	#	#		#	#	#	#	
	Conținutul lui $M_1$	1	$A_1$	$B_1$	$A_2$	$C_1$	$B_2$	$C_2$	$A_2$	$B_1$	$C_1$	$B_2$	$C_2$
		2		$A_1$	$B_1$	$A_2$	$C_1$	$B_2$	$C_2$	$A_2$	$B_1$	$C_1$	$B_2$
		3			$A_1$	$B_1$	$A_2$	$C_1$	$B_2$	$C_2$	$A_2$	$B_1$	$C_1$
Pagina $\frac{p}{2}$	Sirul de referiri	$A_1$	$B_1$	$A_2$	$C_1$	$B_2$	$C_2$	$A_2$	$B_1$	$C_1$	$B_2$	$C_2$	
	Defecte de pagina	#	#	#	#	#	#	#	#	#	#	#	
	Conținutul lui $M_1$	1	$A_1$	$B_1$	$A_2$	$C_1$	$B_2$	$C_2$	$A_2$	$B_1$	$C_1$	$B_2$	$C_2$
		2		$A_1$	$A_1$	$A_2$	$B_1$	$C_1$	$C_2$	$B_2$	$C_2$	$B_1$	$C_1$
		3			$B_1$	$A_1$	$C_1$	$B_2$	$C_1$	$A_2$	$B_1$	$C_1$	$B_2$
	4				$B_1$	$A_2$	$B_1$	$B_2$	$C_2$	$B_2$	$C_2$	$B_1$	

Rezultate:

- algoritm LRU -  $e_p = 7$
- $e_{\frac{p}{2}} = 10$
- $\rho = \frac{10}{7} = 1,43$

• algoritm LRU modificat:

- $e_p = 7$
- $e_{\frac{p}{2}} = 9$
- $\rho = \frac{9}{7} = 1,29$

Fig.38. Utilizarea algoritmului LRU modificat în regiunea cu  $\rho$  moderat.



În regiunea de referire densă, am văzut deja în secțiunea 3 a acestui capitol că utilizarea procedurii propuse de modificare a algoritmilor de înlocuire previne valori extreme ale lui  $\xi$ .

În concluzie, procedura propusă de modificare a algoritmilor de înlocuire fixează o limită superioară pentru raportul  $\xi$  al numerelor defectelor de pagină pentru regiunea cu  $\xi$  mari, fără a micșora valoarea proporției succeselor în regiunile cu  $\xi$  originali mici.

Astfel, prin utilizarea acestei proceduri se crează posibilitatea ca să se obțină îmbunătățiri suplimentare în gestiunea unui sistem ierarhic de memorii prin utilizarea unor dimensiuni reduse de pagină, fără riscul unui consum mare de timp neproductiv datorat activității exagerate de paginare, procedura propusă evitând apariția anomaliei dimensiunii de pagină.

#### 5. Perspective.

Unele probleme tratate în lucrare deschid noi direcții de cercetare. Cea mai importantă ni se pare studiul și elaborarea unor noi algoritmi de înlocuire, spațiali, care să ia în considerație conceptul de localizare spațială. Este posibil să existe și alte soluții în această direcție, pe lângă procedura de modificare a algoritmilor uzuali, propusă în lucrare.

În legătură cu algoritmi modificați, descriși în secțiunea 3, mai rămân probleme nerezolvate. De exemplu, care este relația algoritmilor modificați descriși cu clasa algoritmilor de stivă, studiați de Mattson ș.a. (121) (vezi cap.2, secțiunea 4.1.2.) în particular, în ce condiții, dacă există, un algoritm modificat este un algoritm de stivă. Asemănător, care este relația algoritmilor modificați cu algoritmul de înlocuire teoretic optim, numit OPT (121) sau MIN (18,20).

Din punct de vedere practic, rămâne de arătat cât de eficientă se poate dovedi implementarea unui algoritm de înlocuire modificat conform procedurii propuse sau a unui alt algoritm de înlocuire spațial. În acest scop sînt necesare măsurători ale performanței unui sistem ierarhic de memorii, utilizînd un astfel de algoritm de înlocuire sau cel puțin este necesară o analiză de simulare mai extinsă.

## CAP.7. CONCLUZII

În lucrarea de față s-a realizat cercetarea unei probleme neclarificate pînă în prezent apărute în gestiunea automată a ierarhiilor de memorii și anume situația de apariție a anomaliilor dimensiunii de pagină. Astfel, s-a arătat că, deși prin utilizarea unor dimensiuni mici de pagină în cadrul unei ierarhii de memorii se aduc îmbunătățiri în utilizarea sistemului de memorii, apariția anomaliilor dimensiunii de pagină în cazul utilizării unor dimensiuni reduse de pagină conduce la scăderi în utilizarea sistemului de memorii, cauzate de activitatea exagerată de paginare ce are loc în cadrul acestei anomalii.

Cercetarea acestei probleme, realizată cu ajutorul unui model original al comportării de acces a unui program operînd într-un mediu cu memorie virtuală, stabilește cauzele acestei anomalii și, pe această bază, propune o procedură de modificare a algoritmilor de înlocuire a paginilor utilizați în cadrul gestiunii ierarhiei de memorii, procedură ce evită apariția anomaliilor dimensiunii de pagină.

Procedura propusă de modificare a algoritmilor de înlocuire are un interes practic imediat. Utilizarea ei creează posibilitatea obținerii unor îmbunătățiri suplimentare în gestiunea unui sistem ierarhic de memorii prin utilizarea unor dimensiuni reduse de pagină, fără riscul unui consum mare de timp neproductiv datorat activității exagerate de paginare, procedura propusă evitînd apariția anomaliilor dimensiunii de pagină.

Contribuțiile originale aduse în lucrare de autor, în ordinea din teză, sînt:

1. Prezentarea unitară a problemelor actuale majore ale studiului legat de sistemele ierarhice de memorii (cap.2.
2. Analiza factorilor implicați în alegerea dimensiunii de pagină utilizate în cadrul unei ierarhii de memorii, prezentarea situației de anomalie a dimensiunii de pagină și stabilirea necesității unor studii dedicate acestei probleme (cap.3.);
3. Analiza critică a modelelor analitice descrise în literatură ale comportării de acces a unui program operînd.

- într-un mediu cu memorie virtuală și precizarea inaplicabilității lor în cercetarea problemei anomaliei dimensiunii de pagină (cap.4.);
4. Realizarea unui instrument care să poată fi utilizat în cercetarea anomaliei dimensiunii de pagină, respectiv elaborarea unui model analitic al comportării de acces a unui program. Modelul, ce ține seama de variația dimensiunii de pagină utilizate, stabilește o expresie analitică pentru funcția DPA ce determină valoarea medie a numărului de defecte de pagină, ce apar în decursul execuției unui program într-un mediu cu memorie virtuală (cap.4.);
  5. Studiul proprietăților funcției DPA definite prin modelul elaborat al comportării de acces a unui program (cap.4.);
  6. Regăsirea pe cale analitică, cu ajutorul modelului elaborat al comportării de acces a unui program operînd într-un mediu cu memorie virtuală, a unor rezultate numerice experimentale recunoscute ca semnificative (cap.4.);
  7. Studiul analitic, cu ajutorul modelului elaborat al comportării de acces a programului, a situațiilor de apariție a anomaliei dimensiunii de pagină (cap.5.);
  8. Studiul comportării localizate, temporale și spațiale, a unui program și a modului în care algoritmi de înlocuire uzuali iau în considerație această comportare localizată (cap.5.);
  9. Introducerea conceptului de comportare localizată spațio-temporală și interpretarea cu caracter general, pe baza acestui concept, a apariției anomaliei dimensiunii de pagină (cap.5.);
  10. Identificarea mecanismului de apariție a anomaliei dimensiunii de pagină pe baza cercetării șirului de referiri de pagină a programului (cap.6.);
  11. Elaborarea unei proceduri de prevenire a apariției anomaliei dimensiunii de pagină și descrierea modului ei de aplicare (cap.6.);

12. Modificarea unor algoritmi uzuali de înlocuire pe baza procedurii propuse de prevenire a apariției anomaliilor dimensiunii de pagină și precizarea modului lor de operare (cap.6.);
13. Studiul eficienței algoritmilor modificați prin procedura propusă de prevenire a apariției anomaliilor dimensiunii de pagină (cap.6.);
14. Precizarea unor perspective de interes în domeniu prin indicarea unor noi direcții posibile de cercetare, ca și a unor probleme rămase nerezolvate (cap.6.).

B I B L I O G R A F I E

ABREVIURI

CACM - Communications of the ACM  
JACM - Journal of the ACM  
SJCC - Spring Joint Computer Conference  
FJCC - Fall Joint Computer Conference  
NCC - National Computer Conference  
IEEE-TC - IEEE Transactions on Computers  
IEEE-TEC- IEEE Transactions on Electronic Computers

xxx - Programul Partidului Comunist Român de făurire a societății socialiste multilateral dezvoltate și înaintare a României spre comunism. Congresul XI al PCR, nov.1974.

xxx - Orientările generale cu privire la întocmirea planului cincinal de dezvoltare economico-socială a României în perioada 1981-1985. Conferința Națională a PCR din 7-9 dec.1977

1. Aho, A.V., P.J. Denning și J. Ullman - Principles of Optimal Page Replacement, JACM, 18, 1 (January 1971), 80-93.
2. Amdahl, G.M. și L.D. Amdahl - Fourth-Generation Hardware, Datamation (January 1967).
3. Amelio, G.F. - Charge Coupled Devices for Memory Applications, Proceedings of the 1975 N.C.C., 512-522.
4. Anacker, W. - Superconducting Memories Employing Josephson Devices Proceedings of the 1975 NCC, 529-534.
5. Anacker, W. și C.P. Wong - Performance Evaluation of Computer Systems with Memory Hierarchies, IEEE-TEC EC-16, 6 (December 1967), 765-773.
6. Arden, B.W., B.A. Geller, T.C. O'Brien și F.H. Westervelt - Programming and Addressing Structure in a Time-Sharing Environment, JACM, 13, (1966), 1-16.
7. Arora, S.R. și A. Gallo - Optimal Sizing, Loading and Re-Loading in a Multilevel Memory Hierarchy System, SJCC, 33(1971), 337-344.

8. Auerbach Computer Technology Reports Series,  
Auerbach Publishers Inc.  
Segments A General Purpose Computers  
B Standard Peripherals  
J System Software
9. Auerbach Reporter, Fine-Tuning Virtual Storage for  
Efficiency, Auerbach Publishers Inc., (Dec.1974).
10. Austin, B.J. - A Dynamic Disc Allocation Algorithm  
. Designed to Reduce Fragmentation During File Re-  
Loading, The Computer Journal, 14,4 (1971) 378-  
381.
11. Bard, Y. - Experimental Evaluation of System Perform-  
ance, IBM Syst.J., 12 (1973) 302-316.
12. Bard, Y. - Characterization of Program Paging in a  
Time Sharing Environment, IBM J.Res.Develop 17,  
5 (sept.1973), 387-393.
13. Bard, Y. - Application of the Page Survival Index  
(PSI) to Virtual Memory System Performance, IBM  
J.Res.Develop., 19,3 (May 1975), 212-220.
14. Batson, A., Shy-Ming In si D.C.Wood - Measurements of  
Segment Size, CACM 13, 3 (March 1970), 155-159.
15. Baylis, M.H.J., D.G.Fletcher si D.J.Howarth - Paging  
Studies Made on the ICT Atlas Computer, Proceed-  
ings IFIP Congress 1968, 2, 835-838.
16. Belady, L.A., R.A.Nelson si G.S.Shedler - An Anomaly  
in Space-Time Characteristics of Certain Programs  
Running in a Paging Machine, CACM 12, 6 (June 1969),  
349-353.
17. Belady, L.A. si C.J. Kuehner - Dynamic Space Sharing  
in Computer Systems, CACM 12, 5 (May 1969), 282-288.
18. Belady, L.A. - A Study of Replacement Algorithms for  
a Virtual Storage Computer, IBM Syst.J., 5, 2 (1966),  
78-101.
19. Belady, L.A. - Biased Replacement Algorithms for Multi-  
programming, IBM Thomas Watson Research Center,  
Research Note RC 697 (March 1967).
20. Belady, L.A. si F.P. Palermo - On-Line Measurement of  
Paging Behavior by the Multivalued MIN Algorithm,  
IBM J.Res.Develop., 18, 1 (Jan.1974), 2-19.
21. Bell, G.C. si D.Casasent - Implementation of a Buffer  
Memory in Linicomputers, Computer Design (nov.1971),  
83-89.
22. Bell, G.C. si A. Newell - A Panel Session-Computer  
Structure - Past, Present and Future, FCCC, 1971.
23. Benson, A., C.T.Clingen si R.C.Daley - The Multics  
Virtual Memory, Proceedings of the ACM Second Sym-  
posium on Operating System Principles, Princeton  
University, (Oct.20-22, 1969), 30-42.

24. Bobeck, A.H., F.I. Boneyard, J.E. Gensic - Magnetic Bubbles - An Emerging New Memory Technology, Proceedings of the IEEE, Aug. 1975, 1176-1195.
25. Bogdan R.C., C. Bilciu, A. Davidoviciu și D. Schiopulescu - Memoriile Calculatoarelor Electronice Funcționare și Utilizare, Editura Tehnică, București, 1975.
26. Brawn, B.S. și F.G. Gustavson - Program Behavior in a Paging Environment, Aflps Conference Proceedings, FJCC 33 (1968) 1019-1032.
27. Brewer, J.E. și D.R. Hadden - Block-Oriented Random Access L.NOS Memory, Proceedings of the 1974 NCC, Afips, Vol. 43, 837-840.
28. Bryant, P. - Predicting Working Set Sizes, IBM J. Res. Develop. 19, 3 (May 1975), 221-229.
29. Buzen, J. - Optimizing the Degree of Multiprogramming in Demand Paging Systems, Proceedings of the 1971 International Computer Society Conference.
30. Carnes, J.E., W.F. Kosonocky, J.M. Chambers și D.J. Sauer - Charge-Coupled Devices for Computer Memories, Proceedings of the 1974 NCC, 827-835.
31. Chamberlain, D.D., S.H. Fuller și L.Y. Liu - An Analysis of Page Allocation Strategies for Multiprogramming Systems with Virtual Memory, IBM J. Res. Develop, 17, 5 (sept. 1973), 404-412.
32. Chandy, K.M. - The Analysis and Solution of General Queueing Networks, Proceedings of the Sixth Annual Princeton Conference on Information Sciences and Systems, Princeton University, Princeton, NJ, March 1972.
33. Chandy, K.M., T.W. Keller și J.C. Browne - Design Automation and Queueing Networks: An Interactive System for the Evaluation of Computer Queueing Models, Ninth Annual Design Automation Workshop, Dallas, Texas, June 1972.
34. Chang Hsu - Capabilities of the Bubble Technology, Proceedings of the 1974 NCC, Afips, Vol. 43, 847-855.
35. Chow, C.K. - On Optimization of Storage Hierarchies - IBM J. Res. Develop. 18, 3 (May 1974) 194-203.
36. Chu, W.W. și H. Opderbeck - The Page Fault Frequency Replacement Algorithm, Proceedings 1972 FJCC 41, 597-609.
37. Chu, W.W., N. Oliver și H. Opderbeck - Measurement Data on the Working Set Replacement Algorithm and their Applications - Proceedings 22-ND International Symposium on Computer Communications, Networks and Teletraffic, Polytechnic Institute of Brooklyn Publications, April 1972.
38. Coffman, E.G. - Analysis of a Drum Input/Output Queue Under Scheduled Operation in a Paged Computer System, JACL, 16 (1969), 73.  
xxx ERRATA, JACL 16 (1969), 646.

39. Coffman, E.G. și T.A. Ryan - A Study of Storage Partitioning Using a Mathematical Model of Locality CACM, 15, 3, 1972.
40. Coffman, E.G. și L.C. Varian - Further Experimental Data on the Behavior of Programs in a Paging Environment CACM, 11, 5 (July 1968), 471-474.
41. Coffman, E.G. și R.C. Wood - Interarrival Statistics for Time-Sharing Systems, CACM 9, 7 (July 1966), 500-503.
42. Cojanu M, C. Ionescu - Evoluție și Perspective în Domeniul Memoriilor pentru Sistemele de Calcul, ALC, Vol. 23, 285-298, Editura Tehnică, București, 1976.
43. Considine, J.P. și A.H. Weis - Establishment and Maintenance of a Storage Hierarchy for an On-Line Data Base under TSS/360, PJCC 35 (1969), 433-440.
44. Conti, C.J., D.H. Gibson și S.H. Pitkowsky - Structural Aspects of the System/360 Model 85: I. General Organization, IBM Sys J, 7, 1 (1968), 2-14.
45. Conti, C.J. - Concepts for Buffer Storage, IEEE Computer Group News (March 1969), 6-13.
46. Cook, R.W. și L.J. Flynn - System Design of a Dynamic Microprocessor, IEEE-TC, C-19, 3 (March 1970), 213-222.
47. Corbato, F.J. și V.A. Vycotsky - Introduction and Overview of the Multics System, Afips, PJCC, Afips Press, Spartan, Washington D.C., 1965, 185-196.
48. Daley, R.C. și J.B. Dennis - Virtual Memory, Processes and Sharing in Multics, CACM 11, 5, (May 1968), 306-312.
49. Datapro 70 - The EDP Buyers Bible, Datapro Research Corp., MCGRAW - HILL CO.  
Sections: 70 C Computers  
          70 D Peripherals  
          70 E Software
50. Dell, H.R. - Design of a High-Density Optical Mass Memory System, Computer Design, August 1971, 49-53.
51. De Meis, W.M. și H. Weizer - Measurement and Analysis of a Demand Paged Time-Sharing System, Proceedings 24-TH National Conference of ACM, ACM Publications, Thompson, Washington, D.C., 1969, 201-216.
52. Denning, P.J. - The Working Set Model for Program Behavior, CACM 11, 5 (May 1968), 323-333.
53. Denning, P.J. - Virtual Memory, Computing Surveys, 2, 3 (sept. 1970), 153-183.
54. Denning, P.J. - Third Generation Computer Systems, Computing Surveys, 3, 4 (Dec. 1971), 175-216.
55. Denning, P.J. - Thrashing - Its Causes and Prevention, PJCC 33 (1968), 915-922.



56. Denning, P.J. și S.C. Schwartz - Properties of the Working Set Model, CACM 15 (1972), 191.
57. Denning, P.J. - Memory Allocation in Multiprogrammed Computers, MIT Project MAC, Computation Structures Group, Memo No. 24 (March 1966).
58. Denning, P.J. - Effects of Scheduling on File Memory Operations, Afips Conf. Proc. 30, 1967, SFCC, 9-21.
59. Denning, P.J. și J.R. Spirn - Dynamic Storage Partitioning, 4th ACM Operating System Symposium, IBM Thomas J. Watson Research Center, Yorktown Heights, New-York, Oct. 1973.
60. Denning, P.J. - On Modelling Program Behavior, Proc. SJCC, Afips, Spartan Books, New-York, 1972.
61. Dennis, J.B. - Program Structure in a Multiaccess Computer, MIT Project MAC, Report MAC-TR-11.
62. Dennis, J.B. - Segmentation and the Design of Multiprogrammed Computer System, JACM, 12, 4 (Oct. 1964), 589-602.
63. Dodescu G., D. Ionescu - Memoria Virtuală a Sistemelor de Calcul, ALC, Vol. 23, 263-284, Editura Tehnică, București, 1976.
64. Donovan, J.J. - Systems Programming, MCGRAW-HILL, New York, 1972.
65. Farr, W.W. și W.E. Peisel - An Optimum Disc Organization for a Virtual Memory System, Computer Design (June 1971), 49-54.
66. Femling, D. - Rubber-Band Memory, Electronic Design 13 (June 1971), 64-68.
67. Ferrari, D. - Improving Locality by Critical Working Sets, CACM 17 (1974), 614.
68. Ferrari, D. - Improving Program Locality by Strategy-Oriented Restructuring, Information Processing 74, North-Holland Publishing Co, Amsterdam, 1974, 266-270.
69. Ferrari, D. - Tailoring Programs to Models of Program Behavior, IBM J. Res. Develop. 19, 3 (May 1975), 244-251.
70. Fetch, G.C. - Memory Organization and Hierarchies of Storage Workshop, Computer Group News (Jan. 1969), 24-25.
71. Fikes, R.E., H.C. Lauer și A.L. Varcha-Jr. - Steps towards a General Purpose Time-Sharing System Using Large Capacity Core Storage and TSS/360, Proceedings of the 23-th ACM national Conference (1968), 7-16.
72. Fine, G.H., C.W. Jackson și P.V. McIsaac - Dynamic Program Behavior under Paging, Proceedings 21-th National Conference of ACM, ACM Publications, Thompson, Washington, D.C., (1966), 223-228.
73. Fotheringham, J. - Dynamic Storage Allocation in the Atlas Computer Including an Automatic Use of a Backing Store, CACM-4, 10 (Oct. 1961), 435-436.
74. Freiburger, W.F., U. Grenander și P.D. Sampson - Patterns in Program References, IBM J. Res. Develop., 19, 3 (May 1975), 230-243.

75. Freiberger, I.F. - The Dynamic Behavior of Programs, Afips, FJCC, Afips Press, Thompson, Washington, DC, 1968, 1163-1168.
76. Gaver, D.P., P.A.W. Lewis și G.S. Shedler - Analysis of Exception Data in a Staging Hierarchy, IBM J. Res. Develop., 18, 5 (sept.1974), 423-435.
77. Gecsei, J. - Determining Hit Ratios for Multilevel Hierarchies, IBM J. Res. Develop., 18, 4 (July 1974), 316-327.
78. Gentile, R.B. și R.W. Grove - Mass Storage Utility: Considerations for Shared Storage Applications, IEEE Transactions on Magnetics MAG-7, 4 (Dec.1971) 848-852.
79. Gentile, R.B. și J.R. Lucas Jr. - The Tablon Mass Storage Network, SJCC 38 (1971), 345-356.
80. Gerz, J.L. - Hierarchical Associative Memories for Parallel Computation, MIT Project MAC, Report MAC-TR-69, MIT, Cambridge, Mass. (June 1970).
81. Ghanem, M.Z. - Dynamic Partitioning of the Main Memory Using the Working Set Concept, IBM J. Res. Develop., 19, 5 (sept.1975), 445-450.
82. Ghanem, M.Z. - Study of Memory Partitioning for Multiprogramming Systems with Virtual Memory, IBM J. Res. Develop. 19, 5 (sept.1975), 451-457.
83. Gibson, C.T. - Time-Sharing in the IBM-System/360 Model 67, Proc. Afips, 1966 SJCC, vol.28, Spartan Books, New-York, 61-78.
84. Gibson, D.H. - Considerations in a Block-Oriented System Design, SJCC, 1967.
85. Gillis, A.C., G.E. Hoffman și R.H. Nelson - Holographic Memories - Fantasy or Reality, Proceedings of the 1975 NCC, 535-539.
86. Goldberg, R.P. - Virtual Machine Systems, MIT Lincoln Laboratory, Technical Memorandum No 282-0036 (Aug.1969).
87. Guertin, R.L. - Programming in a Paging Environment, Datamation 13, 2 (Feb.1972), 42-55.
88. Hatfield, D.J. - Experiments on Page Size, Program Access Pattern and Virtual Memory Performance, IBM J. Res. Develop., 16, 1 (Jan.1972), 58-66.
89. Hatfield, D.J. și J. Gerald - Program Restructuring for Virtual Memory, IBM, Syst.J., 10, 3 (1971), 168-192.
90. Hoagland, A.S. - Mass Storage - Past, Present and Future, Computers, 6, 8 (sept.1973), 29-33.
91. Hoagland, A.S. - Magnetic Recording Storage, IEEE Trans on Computers, vol.C-25, No 12, (Dec.1976), 1283-1288.

92. Hodges, D.A. - Alternative Component Technologies for Advanced Memory Systems, Computers 6, 8 (sept.1973), 35-37.
93. Hodges, D.A. - A Review and Projection of Semiconductor Component for Digital Storage, Proceedings of the IEEE, Aug. 1975, 1136-1147.
94. Hodges, D.A. - Trends in Computer Hardware Technology, Computer Design, vol.15, No.2, (Feb.1976), 77-85.
95. Hughes, W.C., C.Q. Leimond, H.G. Parks, G.W. Ellis, G.E. Possin și R.H. Wilson - Beamos - A New Electronic Digital Memory, Proceedings of the 1975 ICC, 541-549.
96. IBM - A Guide to the IBM System/370 Model 158, GC 20-1754-2 File No.S/370-01.
97. IBM - A Guide to the System/370 Model 165, Form NR GC 20 - 1730 (June 1970), 19-25.
98. IBM - System/370 - System Summary, GA 22-7001-4 File No S/370-01
99. IBM - Virtual Machine Facility/370 Introduction, Form No GC 20-1800., IBM Data Processing Division, White Plains, N.Y., 1972.
100. ICL - Documentație tehnică privind seria de calculatoare ICL-21
101. Irani, K.B. și V.L. Wallace - On Network Linguistics and the Conversational Design of Queueing Networks, JACM, Oct.1971.
102. Joseph, L. - An Analysis of Paging and Program Behavior - The Computer Journal, 13, 1 (Feb.1970), 48-54.
103. Kaneko, T. - Optimal Task Switching Policy for Multilevel Storage System, IBM J.Res.Develop. 18, 4 (July 1974), 310-315.
104. Katzan, H.Jr. - Storage Hierarchy Systems, SJCC, Arips Press, 38 (1971), 325-336.
105. Kilburn, T., D.B.G. Edwards, M.J. Lanigan și F.H. Summer - One-Level Storage Systems, IEEE-TEC, EC-11, 2 (April 1962), 223-235.
106. Kotak, A. - Lecture Notes CS 252, Digital Equipment Co., Marlborough, Mass., 1976.
107. Laliotis, T.A. - Main Memory Technology, Computers, 6, 8 (sept. 1973), 21-27.
108. Lauer, H.C. - Bulk Core in a 360/67 Time-Sharing System, Computer Design 7, 4 (April 1968), 94-101.
109. Lee, F.F. - Study of a Look-Aside Memory, IEEE-TEC, C-18, 11 (Nov.1969).
110. Lew, A. - On Optimal Pagination of Programs, University of Hawaii Information Sciences Report, Honolulu, Hawaii, (May 1970).
111. Lewis, P.A.W. și G.S. Shedler - Empirically Derived Micromodels for Sequences of Page Exceptions, IBM J.Res.Develop., 17, 2 (March 1973), 86-100.
112. Lewis, P.A.W. și G.S. Shedler - A Cyclic Queue Model of System Overhead in Multiprogrammed Computer System, JACM 18, 2, (April 1971), 199-220.

113. Lewis, P.A.W. și P.C.Yue - Statistical Analysis of Program Reference Patterns in a Paging Environment, Proceedings of the 1971 International Computer Society Conference (sept.1971) 133-134.
114. Lin, Y.S. și R.L. Mattson - Cost-Performance Evaluation of Memory Hierarchy, IEEE Trans.Magnetics, Mag.-8 (1972), 390.
115. Liptay, J.S. - Structural Aspects of the System/360 Model 85. II The Cache, IBM Syst.J.7, 1 (1968), 15-21.
116. Lorin, H. - Parallelism in Hardware and Software, Prentice Hall, Inc., Englewood Cliffs, New-Jersey, 1972.
117. Mackenzie, F.B. - Automated Secondary Storage Management, Datamation 11, 11 (1965), 24-25.
118. Mahl, R. - An Analytical Approach to Computer Systems Scheduling, University of Utah (June 1970).
119. Martinson, J.R. - Utilization of Virtual Memory in Time-Sharing System/360, IBM Tr.53.0001, IBM Systems Development Division, Yorktown Heights, N.Y. (Oct.1968).
120. Mattson, R.L. - Evaluation of Multilevel Memories, Memorandum, IBM Research Laboratory, San-Jose, Calif., 1971.
121. Mattson, R.L., J.Gecsei, D.R.Slutz și J.L. Traiger - Evaluation Techniques for Storage Hierarchies, IBM Syst.J. 9, 2 (1970), 78-117.
122. Mazda, F. - Large Scale Integrated Memories - Electronic Components, 53, 13 (Sept.1972), 876-884.
123. Meade, R.M. - On Memory System Design, ESD: 3 (1970), 33-43.
124. Meade, R.M. - How a Cache Memory Enhances a Computer's Performance, Electronics, (Jan.1972), 58-63.
125. Meyer, R.A. și L.H.Seawright - A Virtual Machine Time-Sharing System, IBM Syst.J., 9, 3 (1970), 199-218.
126. Korenoff, E. și J.B.Mclean - Application of Level-Changing to a Multilevel Storage Organization, CACM 10, 3 (March 1967), 149-154.
127. Kosuda, T., H.Shiota, K.Foguchi și T.Okki - Optimization of Program Organization by Cluster Analysis, Information Processing 74, North Holland Publishing Co, Amsterdam 1974, 261.
128. Oden, P.H. și G.S.Shedler - A Model of Memory Contention in a Paging Machine, CACM, 15, 8 (Aug.1972), 761-771.
129. O'Neil, R.W. - Experience Using a Time-Sharing Multi-Programming System with Dynamic Address Relocation Hardware, AFIPS Conf.Proc.30, SJCC (1967), 611-621.
130. O'Neil, R.W. și B.H.Sans - Preplanned Vs.Dynamic Storage Allocation Techniques, CACM, 4, 10 (Oct.1961) 416-418.

131. Oppenheimer, G. și H. Weizer - Resource Management for a Medium Scale Time-Sharing Operating System, CACM, 11, 5 (May 1968), 313-322.
132. Opran, M. - Memoriile Calculatoarelor Electronice, Sinteză Documentară, I.D.T., 1972.
133. Organick, E.I. - The Multics System - MIT Press, Cambridge, Mass. (1972).
134. Penny, S.J., R. Fink și M. Alston - Garnjost - Design of a Very Large Storage System, FJCC 37 (1970), 45-51.
135. Ramamoorthy, C.V. - The Analytic Design of a Dynamic Look-Ahead and Program Segmenting System for Multiprogrammed Computers, Proc. 21 Nat. Conf. ACM (1966).
136. Ramamoorthy, C.V. și K.M. Chandy - Optimization of Memory Hierarchies in Multiprogrammed Systems, JACM 17, 3 (July 1970), 426-445.
137. Randell, B. - A Note on Storage Fragmentation and Program Segmentation, CACM, 12, 7 (July 1969), 365-372.
138. Randell, B. și C.J. Kuehner - Dynamic Storage Allocation Systems, CACM 11, 5 (May 1968), 297-306.
139. Rege, S.L. - Performance and Power Dissipation Analysis for CCD Memory Systems, Proceedings of the 1976 NCC, 381-391.
140. Rodriguez, R.J. - Experimental Data on how Program Behavior Affects the Choice of Scheduler Parameters, 3-rd ACM Symposium on Operating System Principles, ACM Publications, Stanford Univ., Stanford, Calif., (oct. 1971), 156-163.
141. Rodriguez, R.J. și J.P. Dupuy - The Design, Implementation and Evaluation of a Working Set Dispatcher, CACM 16 (1973), 247.
142. Rodriguez, R.J. - Empirical Working Set Behavior, CACM, 16 (1973), 556.
143. Rogoian, A.I. - Curs de Calculatoare Numerice, vol. 1 și 2, Ed. I.P.T., Timișoara, 1973.
144. Ryder, K.D. - Optimizing Program Placement in Virtual Systems, IBM Syst. J. 13 (1974), 292.
145. Sayre, D. - Is Automatic Folding of Program Efficient Enough to Displace Manual?, CACM 12, 12 (Dec. 1969), 656-660.
146. Scarrot, G. - Optical Memory, The Radio and Electronic Engineering, 40, 2 (Aug. 1970), 89-95.
147. Schwetman, H.D. - A Study of Resource Utilization and Performance Evaluation of Large Scale Computer Systems, TSN-12, Computation Center, the University of Texas at Austin, July 1970.
148. Seligman, L. - Experimental Data for the Working Set Model, MIT Project MAC, Computation Structures Group, Memo No 39, MIT, Cambridge, Mass. (March 1968).
149. Shedler, G.S. și C. Tung - Locality in Page-Reference Strings, SIAL J. On Computing 1, 3 (1972) 218-241.

150. Shedler, G.S. și S.C. Yang - Simulation of a Model of Paging System Performance, IBM Syst.J. 2 (1971).
151. Shemer, J.E. și G.A. Shippey - Statistical Analysis of Paged and Segmented Computer Systems, IEEE T-EC, EC-15, 6 (Dec.1966).
152. Sherman, S., P. Basket și J.C. Browne - Trace Driven Modelling and Analysis of CPU Scheduling in a Multiprogramming System, Proceedings ACM-Sigops Workshop on System Performance Evaluation, Cambridge, Mass., (April 1971).
153. Smith, J.L. - Multiprogramming under a Page on Demand Strategy, CACM 10, 10 (Oct.1967), 636-646.
154. Spain, K.J., H.I. Jauvtis și F.T. Durben - Dot Memory Systems, Proceedings of the 1974 NCC, Afips, vol.43, 841-846.
155. Spiliotis, D.E. - Bridging the Memory Access GAP, Proceedings of the 1975 NCC, 501-508.
156. Spirn, J.R. - A Model for Dynamic Allocation in a Paging Machine, 8th Annual Princeton Conference on Information Sciences and Systems, Princeton University (March 1974).
157. Thompson, S., J.A. Morton și A. Bobeck - Memories-Future Storage Techniques, The Electronic Engineer (Aug. 1971), 33-39.
158. Traiger, I.L. și R.L. Mattson - The Evaluation and Selection of Technologies for Computer Storage Systems, Magnetism and Magnetic Materials-1971, AIP Conference Proceedings nr.5, part 1, (1972), 1-9.
159. Varian, L.C. și E.G. Coffman - An Empirical Study of the Behavior of Programs in a Paging Environment, ACM Symposium on Operating System Principles, Gatlinburg, Tennessee, (Oct.1967).
160. Vysotsky, V.A. - Structure of the Multics Supervisor, Afips Conf.Proc.27, FJCC (1965).
161. Waas, G.J. - Electronic Memories. A Review of Semiconductor Devices, Control Engineering, 19, 1 (Jan.1972), 57-63.
162. Wallace, V.L. și D.L. Mason - Degree of Multiprogramming in Page on Demand Systems, CACM 12, 6 (June 1969), 305-313.
163. Walter, C.J., A.B. Walter și M.J. Bohl - Impact of Fourth Generation Software on Hardware Design, IEEE Computer Group News (July 1968), 1-10.
164. Weizer, N. și G. Oppenheimer - Virtual Memory Management in a Paging Environment, Afips, SJCC, Afips Press., Montvale, N.Y., 1969, 234-249.
165. Wilkes, M.V. - Slave Memories and Dynamic Storage Allocation, IEEE-TEC 14, 2 (April 1965), 270-271.

166. Williams, J.G. - Large Core Storage in Perspective, Computer Design 11, 1 (Jan.1972), 45-49.
167. Winograd, J., S.J.Morgenstein și R.Herman - Simulation Studies of a Virtual Memory, Time-Shared, Demand Paging Operating Systems, 3-rd ACM Symposium on Operating Systems Principles, ACM Publications, Stanford University, Stanford, Calif. (Oct.1971).
168. Woolf, A.M. - Analysis and Optimization of Multiprogrammed Computer Systems Using Storage Hierarchies, University of Michigan, Ann Arbor, Michigan, Systems Engineering Laboratory, Sel Technical Report nr.53 (April 1971).
169. Ypma, J.E. - Bubble Domain Memory Systems, Proceedings of the 1975 FCC, 523-528.
170. xxx - Single-Chip Microcomputers.Focus of Intense Price Battle, Electronic News, vol.22, no.1197, Lunday, nov.7, 1977.