

3. PARTIȚIONAREA PENTRU CIRCUITELE CU RESURSE LIMITATE DE RUTARE

3.1 Introducere

Partiționarea este tehnica de divizare a unui circuit sau sistem într-o colecție de părți de dimensiune mai mică (componente). Pe de o parte, partiționarea este o etapă de proiectare pentru divizarea unui sistem în mai multe părți care pot fi implementate prin componente separate, iar pe de altă parte partiționarea reprezintă o metodă algoritmică pentru rezolvarea problemelor complexe de optimizare care apar în sinteza logică sau în proiectarea fizică a circuitelor VLSI. În literatură a fost publicat un număr mare de lucrări care tratează problema de partiționare a grafurilor sau a circuitelor [14], [23], [31], [33], [39], [40], [41], [49], [50], [51], [69], [70], [76], [85], [86], [89], [90], [94], [95], [97], [98], [105], [106], [116], [129], [130], [138], [139], [146], [155], [156], [168], [175], [176], [180], [181], [183], [186], [189].

Există aplicații ale partiționării la toate nivelele de abstractizare, de exemplu la nivel funcțional și la nivel structural [98]. În primele etape ale procesului de proiectare, trebuie luate decizii de partiționare a sistemului, bazate adeseori pe cunoștințe incomplete. În particular, trebuie să se decidă dacă o componentă va fi implementată prin hardware sau prin software, pentru a se obține un raport optim dimensiune/performance. Deoarece partiționarea complet automată este esențială pentru iterații rapide în ciclul de proiectare, există eforturi considerabile pentru a facilita și a îmbunătăți deciziile dificile la nivel funcțional.

Componentele care rezultă din partiționarea sistemului sunt implementate de proiectanți sau sunt sintetizate dintr-o descriere de nivel înalt prin utilizarea unor utilitare de sinteză care generează o implementare structurală. În cazul în care componentele hardware au o complexitate prea mare datorită restricțiilor de spațiu sau a numărului de terminale, acestea sunt partiționate din nou la nivel structural pe baza unor obiecte ca module sau celule. Subiectul partiționării la nivel structural este studiat extensiv în literatură.

Pe măsura creșterii complexității sistemelor digitale, este necesară partiționarea acestora pentru simplificarea procesului de proiectare și sinteză. Această descompunere a problemei de sinteză este reflectată în organizarea ierarhică a plăcilor, modulelor multi-cip, circuitelor integrate și a macro celulelor. La nivelele inferioare ale ierarhiei de proiectare, în general întârzierile semnalelor scad; de exemplu, comunicarea în cadrul unui circuit integrat este mai rapidă decât comunicarea între două circuite. De aceea, metrica tradițională pentru partiționare este numărul de conexiuni sau semnale existente între părți. Esența partiționării o reprezintă minimizarea acestui număr.

Orice decizie luată în primele etape a procesului de proiectare va influența deciziile ulterioare. De aceea, soluțiile problemelor de plasare, rutare globală și rutare detaliată depind de calitatea algoritmului de partiționare. După cum au arătat autori ca

Wei și Cheng [175], Hagen și Kahng [86], sau Johannes [98], partiționarea este importantă pentru numeroase probleme fundamentale CAD, dintre care se amintesc următoarele:

- *Încapsularea circuitelor*: Logica este partiționată în blocuri, ținând cont de limitările numărului pinilor de I/E și de restricțiile suprafeței unui bloc; această partiționare se efectuează la fiecare îmbunătățire a tehnologiei, atunci când circuitele existente trebuie reîncapsulate în blocuri de capacitate mai mare.
- *Plasare*: Partiționarea este utilizată în acest caz pentru a obține o listă de conexiuni grupată care este utilizată apoi pentru plasarea constructivă a modulelor.
- *Sinteza de nivel înalt*: Precizia cu acuratețe a suprafeței de amplasare a modulelor și a conectivității este importantă pentru sinteza de nivel înalt; modelele de predicție se bazează pe analiza structurii de partiționare a listelor de conexiuni împreună cu modele pentru algoritmi de plasare și rutare.
- *Simulare hardware și test*: O partiționare de calitate va minimiza numărul semnalelor inter-blocuri care trebuie multiplexate de un simulator hardware; similar, reducerea numărului de intrări la un bloc va reduce adesea și numărul vectorilor necesari pentru simularea logicii.
- *Prototipizare rapidă bazată pe circuite FPGA*: Emularea sistemelor și prototipizarea rapidă bazată pe rețele de circuite FPGA este din ce în ce mai răspândită. Pentru a obține cel mai scurt ciclu de proiectare, partiționarea automată a sistemului este absolut necesară. Deoarece numărul circuitelor FPGA, tipul lor și interconectarea acestora sunt date, partiționarea constă în a găsi o mapare a obiectelor sistemului la circuitele FPGA, cu satisfacerea unor restricții ca numărul blocurilor logice ale circuitelor, numărul de pini, sau întârzierile unor căi critice. Partiționarea pentru circuite FPGA multiple este una din aplicațiile cele mai des studiate în articolele recente [23], [90], [95], [179], [181].
- *Amplasarea componentelor*: Această problemă este în strânsă legătură cu partiționarea. Dacă este dată partiționarea sistemului în blocuri, sarcina amplasării este de a determina pozițiile relative ale blocurilor, dimensiunile lor și poziția pinilor, pentru a se optimiza spațiul ocupat în cadrul circuitului, respectându-se restricțiile de întârziere a semnalelor. Amplasarea optimă depinde în mare măsură de calitatea partiționării. Problema amplasării este dificilă deoarece este posibil ca unele părți ale circuitului să nu fie complet specificate sau implementate, ceea ce face ca estimarea cu acuratețe a parametrilor unui bloc să fie esențială.
- *Partiționarea algoritmilor DSP*: Partiționarea algoritmilor procesoarelor de semnal pentru sistemele multi-procesor este dificilă din cauza numeroaselor restricții. Programarea procesoarelor de semnal este realizată prin maparea unei specificații funcționale pe o rețea dată de procesoare. Este esențial ca această operație să fie realizată în mod automat pentru a se putea investiga rapid diferite arhitecturi și soluții.
- *Co-proiectare hardware/software*: Sistemele microelectronice constau de obicei din părți hardware specifice aplicației și părți software. Componentele hardware asigură performanțe mai ridicate, având însă și costuri mai ridicate, în timp ce componentele software sunt mai flexibile și mai puțin costisitoare. Un proiectant de sistem va realiza o partiționare în componente hardware și software care satisface toate restricțiile de performanță, menținând în același timp costul componentelor hardware la minimum necesar.

3.2 Definirea problemei de partiționare

Problema de partiționare a circuitelor se poate formula ca o problemă de partiționare a grafurilor. Un model matematic standard al circuitelor asociază un graf $G = (V, E)$ cu lista de conexiuni a circuitului, unde vârfurile din V reprezintă elemente de circuit (module), iar muchiile din E reprezintă interconexiuni. Vârfurile și muchiile grafului G pot fi ponderate pentru a reflecta suprafața ocupată de modul sau importanța unei conexiuni. Dacă se consideră circuitul din Figura 3.1(a), modelul sub forma unui graf al acestui circuit este indicat în Figura 3.1(b). Se observă că toate interconexiunile sunt conexiuni cu doi pini. De exemplu, conexiunea pinilor de intrare ale porților 5 și 6 este modelată ca o muchie între nodurile 5 și 6 în Figura 3.1(b).




Figura 3.1. (a) Exemplu de circuit. (b) Graful corespunzător circuitului.

Există două formulări de bază ale problemei de bipartiționare a circuitelor. Acestea sunt următoarele [86]:

- *Tăietura minimă*: Fiind dat graful $G = (V, E)$, se partiționează V în subseturile disjuncte U și W astfel încât $e(U, W)$, adică numărul muchiilor în $\{(u, w) \in E \mid u \in U \text{ și } w \in W\}$, este minimizat.
- *Bisecția de lățime minimă*: Fiind dat graful $G = (V, E)$, se partiționează V în subseturile disjuncte U și W , cu $|U| = |W|$, astfel încât $e(U, W)$ este minimizat.

Deoarece bisecția de lățime minimă împarte modulele astfel încât numărul acestora este egal în cele două partiții, acesta reprezintă un obiectiv mai des utilizat pentru circuitele reale.

Problema mai generală de partiționare este cea în care se formează k subseturi disjuncte. Aceasta se numește partiționare cu k căi și este definită astfel [146]:

- Fiind dat un graf $G = (V, E)$, unde fiecare vârf $v \in V$ are o dimensiune $s(v)$, iar fiecare muchie $e \in E$ are o pondere $w(e)$, se divide setul V în k subseturi V_1, V_2, \dots, V_k , astfel încât să se optimizeze o funcție obiectiv, ținând cont de anumite restricții.

Restricțiile sunt analizate în secțiunea 3.3.

Deoarece listele de conexiuni au adesea mai mult de doi pini, o listă de conexiuni poate fi reprezentată mai general printr-un *hipergraf* $H = (V, E)$, unde hipermuchiiile din E sunt subseturile lui V conținute de fiecare conexiune. O mare parte din literatură tratează partiționarea grafurilor în loc de partiționarea hipergrafurilor, deoarece formularea este mai simplă, și un număr mare de algoritmi sunt aplicabili numai pentru grafuri.

3.3 Restricții

În cadrul modelului sub formă de graf, dimensiunea $s(v)$ a unui nod v reprezintă suprafața elementului de circuit corespunzător. Dacă presupunem că circuitul este partiționat în k subcircuite, partiționarea împarte graful $G = (V, E)$ în k subgrafuri $G_i = (V_i, E_i)$, $i = 1, 2, \dots, k$. În Figura 3.1(a), dacă circuitul se partiționează în două subcircuite, cu porțile 2, 3, 4 într-o partiție și porțile 1, 5, 6 în cealaltă, cele două subgrafuri sunt indicate în Figura 3.1(b). Subgraful G_1 constă din nodurile 2, 3, 4 și muchiile (2, 4) și (2, 3), iar subgraful G_2 constă din nodurile 1, 5, 6 și muchia (5, 6). Muchiile (5, 4), (1, 2) și (4, 6) sunt 'tăiate' de partiție. Numele *set de tăietură* este utilizat pentru a descrie setul acestor muchii. Setul de tăietură al unei partiții este indicat prin ψ și este egal cu setul muchiilor tăiate de partiție.

Fiind dat un set de noduri V interconectate prin muchiile e_1, \dots, e_n , există numeroase restricții care pot fi impuse unei probleme de partiționare. De exemplu, se poate specifica găsirea unei partiții (V_1, \dots, V_k) care satisface una sau mai multe din următoarele restricții:

1. Se specifică o dimensiune $s(v)$ pentru fiecare $v \in V$ și o limită superioară de dimensiune S , cerându-se ca dimensiunea fiecărui nod V_i să fie cel mult S .
2. Sunt specificate valorile întregi pozitive n_1, \dots, n_k , și se cere ca numărul de elemente din V_i să fie n_i , deci $|V_i| = n_i$, pentru fiecare $i = 1, \dots, k$.
3. Se specifică o limită P a numărului de pini, și se cere ca numărul de pini din fiecare V_i să fie cel mult P , deci $P_i \leq P$, pentru fiecare $i = 1, \dots, k$.
4. Trebuie minimizată valoarea tăieturii totale a tuturor muchiilor, și anume $\sum_{i=1}^n c(e_i)$. Cantitatea $\sum_{i=1}^n c(e_i)$ este numită și dimensiunea tăieturii partiției. Pentru o bipartiție, dimensiunea tăieturii este egală cu numărul de conexiuni tăiate de partiție.
5. Pentru fiecare muchie e_i este specificată o pondere $w(e_i)$, cerându-se ca valoarea tăieturii totale ponderate a tuturor muchiilor, deci $\sum_{i=1}^n w(e_i)c(e_i)$, să fie minimizată. Cantitatea $\sum_{i=1}^n w(e_i)c(e_i)$ este numită și dimensiunea ponderată a tăieturii partiției.
6. Se dă o submulțime *TEST* a muchiilor care sunt desemnate ca *testabile*, și se cere ca fiecare muchie din *TEST* să fie externă sau tăiată de partiție, deci $c(e) > 0$ pentru fiecare $e \in TEST$.
7. Un set *CRIT* al muchiilor care sunt desemnate ca fiind *critice* trebuie să fie intern sau netăiat de partiție, deci $c(e) = 0$ pentru fiecare $e \in CRIT$.

În cazul problemei generale de partiționare cu k căi, restricția de dimensiune este exprimată prin plasarea unei limite superioare asupra dimensiunii fiecărui subcircuit. Dimensiunea subcircuitului i este dată prin $\sum_{v \in V_i} s(v)$. Dacă limita superioară a dimensiunii acestui subcircuit este S_i , avem:

$$\sum_{v \in V_i} s(v) \leq S_i \quad (3.1)$$

Este de dorit ca circuitul să fie împărțit în partiții de dimensiuni aproximativ egale. Aceasta se poate exprima prin modificarea ecuației 3.1 după cum urmează:

$$|V_i| = \sum_{v \in V'} s(v) \leq \left\lceil \frac{1}{k} \sum_{v \in V'} s(v) \right\rceil = \frac{1}{k} |V| \quad (3.2)$$

unde $|V_i|$ și $|V|$ reprezintă dimensiunile seturilor V_i respectiv V . Dacă toate elementele de circuit au aceeași dimensiune, ecuația 3.2 se reduce la:

$$n_i \leq \frac{n}{k} \quad (3.3)$$

unde n_i și n reprezintă numărul elementelor din V_i respectiv V .

Dacă subcircuiturile sunt implementate în capsule separate, sunt necesare legături externe între acestea. În particular, conexiunile care aparțin setului de tăietură vor fi implementate ca și legături externe. Legăturile externe nu sunt de dorit, deoarece introduc întârzieri suplimentare. De aceea este necesară minimizarea acestor legături externe. Ponderele $w(e)$ a unei muchii e a grafului circuitului reprezintă costul implementării conexiunii respective ca o legătură externă. Astfel, funcția de cost care trebuie minimizată în timpul partiționării este:

$$Cost = \sum_{\psi} w(e) \quad (3.4)$$

Presupunem că partițiile sunt numerotate 1, 2, ..., k . Fie $p(u)$ numărul partiției nodului u . Condiția $e \in \psi$ poate fi scrisă ca $e = (u, v)$, și $p(u) \neq p(v)$. Astfel, ecuația 3.4 poate fi rescrisă ca:

$$Cost = \sum_{\forall e=(u,v) \& p(u) \neq p(v)} w(e) \quad (3.5)$$

3.4 Prezentarea sintetică a metodelor de partiționare

Problema de partiționare, după cum este formulată în secțiunea 3.2, este o problemă intractabilă [146]. Chiar și cazul cel mai simplu al problemei, și anume bipartiționarea cu dimensiuni egale ale nodurilor și ponderi unitare ale muchiilor, este o problemă NP-completă. Pentru un circuit cu $2n$ noduri, numărul partițiilor echilibrate crește exponențial cu n . Chiar pentru valori moderate ale lui n , este impractică enumerarea tuturor partițiilor și alegerea celei mai bune. Singurul mod de a rezolva asemenea probleme NP-complete este de a obține soluții aproximative. O asemenea soluție trebuie să satisfacă restricțiile cerute, dar costul obținut nu este neapărat cel minim.

Există diferite tehnici euristice pentru a se genera soluții aproximative ale problemei de partiționare [98], [146]. Acestea se pot clasifica în algoritmi *deterministici* și *stohastici* (probabilistici). Un algoritm deterministic generează aceeași soluție la fiecare execuție, deoarece deciziile pe care le ia sunt deterministice. O metodă stohastică se bazează pe decizii aleatoare pentru generarea soluției, astfel că o asemenea metodă generează soluții diferite pentru aceleași intrări.

Metodele de partiționare pot fi clasificate de asemenea ca fiind *constructive* și *iterative*. O metodă constructivă pornește de la o anumită componentă nucleu (sau mai multe asemenea componente), selectând apoi alte componente pentru a fi adăugate la soluția parțială, până la obținerea unei soluții complete. Odată ce o componentă este selectată pentru a aparține unei partiții, ea nu mai este mutată în etapele următoare ale procedurii de partiționare. O metodă iterativă are ca scop îmbunătățirea calității unei soluții existente de partiționare, de exemplu reducerea costului. De multe ori, o asemenea metodă se aplică pentru îmbunătățirea soluției generate de o metodă

constructivă. De obicei metodele constructive sunt deterministice, în timp ce metodele iterative pot fi deterministice sau stohastice.

Metodele constructive de partiționare se bazează în principal pe grupare, metode spectrale sau vectori proprii, partiționare bazată pe plasare, programare matematică, sau calcule ale fluxului în rețele.

Gruparea este o tehnică pentru a determina componentele puternic conectate ale unui graf. Pentru partiționarea unor circuite conținând milioane de module gruparea de jos în sus este combinată adesea cu partiționarea de sus în jos. O formulare care unifică ambele strategii a fost publicată în [94]. Gruparea a fost aplicată de asemenea pentru optimizarea performanțelor [136], [179], [184]. Structuri formate din setul tuturor nodurilor unui bloc combinational între o singură ieșire și intrările care conduc la această ieșire, au fost aplicate la partiționarea de jos în sus a circuitelor FPGA pentru căi critice [23]. În acest caz, considerarea direcției semnalelor a determinat îmbunătățirea soluției de partiționare. Compromisul între timpul de execuție și performanță este investigat în [185]. În [109] se descrie o metodă de grupare în care informațiile globale de conectivitate ale grafului sunt obținute din proprietatea de grupare a metodei vectorilor proprii.

Tehnicile de programare matematică sunt utilizate pentru optimizarea unei funcții obiectiv sub restricțiile unor inegalități. Pentru rezolvarea problemelor de partiționare au fost aplicate programarea quadratică [139], programarea booleană quadratică [155], programarea liniară [116].

Metodele spectrale au fost propuse în ultimii ani [39], [40], [86], [109]. Pe baza matricii de adiacență a grafului, obiectivul tăieturii minime poate fi rescris ca un sistem de ecuații. Vectorul propriu al valorii proprii minime diferite de zero a matricii poate fi interpretat ca o plasare liniară sau ordonare a nodurilor grafului. Această ordonare poate fi divizată pentru a obține o partiționare a nodurilor. În literatură au fost publicate numeroase modificări ale acestei metode de bază, inclusiv utilizarea mai multor vectori proprii. În cazul partiționării cu căi multiple s-a demonstrat faptul că odată cu creșterea numărului de vectori proprii, crește calitatea partiționării.

Partiționarea bazată pe plasare este strâns legată de metodele spectrale. Aceste metode minimizează o funcție obiectiv quadratică. Pentru plasare, s-a arătat că minimizarea unui obiectiv liniar conduce la rezultate îmbunătățite. În [139] această observație a fost utilizată pentru obținerea unor partiționări de calitate mai bună. Deoarece plasarea cu un obiectiv liniar este derivată din plasarea bazată pe vectori proprii, această metodă poate fi clasificată și ca o metodă de îmbunătățire iterativă. Această metodă bazată pe plasare a fost de asemenea extinsă la partiționarea cu căi multiple cu aplicații la circuitele FPGA [138].

În cazul metodelor bazate pe fluxul în rețele, fluxul direcționat al semnalelor poate fi utilizat pentru îmbunătățirea performanțelor sistemului. Au fost propuse diferite tipuri de formulări ale fluxului în rețele [67], [94], [95], [116], [180], [181], [184]. Toate acestea au în comun faptul că este generat un model al grafului din lista de conexiuni direcționată pentru a determina un flux maxim care este echivalent cu o tăietură minimă.

Metodele constructive stohastice nu au fost utilizate frecvent pentru soluționarea problemelor de partiționare. Exemple mai recente sunt [90] și [184]. În [90] este determinată o ordonare liniară prin selectarea aleatoare a unor noduri de început. Prin utilizarea programării dinamice ordonarea este divizată în grupe. În [184] este propusă o metodă probabilistică pentru a reduce complexitatea computațională a algoritmului bazat pe flux.

Au fost publicate numeroase metode deterministice iterative. Acestea inter-schimbă în mod iterativ noduri sau perechi de noduri pentru a minimiza numărul de muchii tăiate. Din acest motiv, acestea sunt indicate în mod colectiv ca algoritmi de tăietură minimă. Cele mai multe din acestea sunt de tip greedy [105], [146], [189]. Acești algoritmi diferă în mod semnificativ în alegerea funcției obiectiv utilizate. Un obiectiv

îmbunătățit bazat pe calculul probabilistic al câștigurilor este introdus în [69]. Cele mai multe implementări utilizează configurații inițiale aleatoare multiple [175] pentru căutarea adecvată în spațiul soluțiilor și a obține o anumită măsură de "stabilitate", deci, de performanțe predictibile. În [50] a fost propusă o metodă de bipartiționare cu performanțe stabile, care nu necesită generarea unui mare număr de configurații inițiale. Se utilizează o tehnică de partiționare recursivă de sus în jos, și se divide întregul circuit în grupuri mici, puternic conectate, care sunt apoi rearanjate în două subseturi care respectă restricția de dimensiune.

Îmbunătățirea iterativă poate fi combinată cu gruparea pentru a reduce complexitatea calculelor. Deoarece metodele iterative deterministice sunt sensibile la modul de alegere a partiției inițiale, în [117] a fost propusă o metodă bazată pe gradient pentru a elimina acest dezavantaj. Au fost propuse și metode de partiționare de tăietură minimă bazate pe programarea quadratică.

Metodele stohastice de îmbunătățire iterativă utilizate în mod obișnuit sunt călirea simulată și evoluția simulată [76], [189]. Cel mai important avantaj al acestora este că pot evita minimele locale. O evaluare experimentală a bipartiționării în [186] arată că prin călirea simulată se obțin anumite avantaje în privința calității soluției, dar timpul de calcul consumat este foarte mare.

Ca exemple de metode deterministice vor fi prezentate euristiciile Kernighan-Lin și Fiduccia-Mattheyses în secțiunile 3.4.1, respectiv 3.4.3. Variante ale euristicii Kernighan-Lin sunt prezentate în secțiunea 3.4.2. Euristica stohastică de călire simulată este prezentată în secțiunea 3.4.4. În secțiunea 3.4.5 este descrisă metoda de partiționare care utilizează tăietura proporțională, o metrică propusă de Wei și Cheng, care s-a dovedit o funcție obiectiv de succes pentru numeroase aplicații. O metodă de partiționare cu performanțe stabile, care nu depind de alegerea partiției inițiale, este descrisă în secțiunea 3.4.6. Metodele spectrale de partiționare, care utilizează valori proprii și vectori proprii ale matricilor obținute din graful circuitului, sunt prezentate în secțiunea 3.4.7. În secțiunea 3.4.8 se descrie o metodă pentru modelarea unei liste de conexiuni printr-o rețea de flux, și o euristica de bipartiționare echilibrată bazată pe utilizarea repetată a tehnicii fluxului maxim și tăieturii minime. Un algoritm de multi-partiționare cu îmbunătățire iterativă, care poate utiliza diferite funcții obiectiv cu aplicații în proiectarea circuitelor VLSI, este prezentat în secțiunea 3.4.9. În sfârșit, partiționarea prin metode probabilistice este prezentată în secțiunea 3.4.10.

3.4.1 Algoritmul Kernighan-Lin

Acest algoritm este unul din cele mai utilizate pentru rezolvarea problemei de bipartiționare. Algoritmul Kernighan-Lin (KL) a fost elaborat inițial pentru biseccionarea grafurilor, și a fost extins apoi pentru rezolvarea problemei de biseccionare a circuitelor [189].

Problema de bipartiționare este caracterizată printr-o matrice de conectivitate C , care este o matrice pătrată cu un număr de linii egal cu numărul de noduri ale grafului circuitului. Elementul c_{ij} reprezintă suma ponderilor muchiilor care conectează elementele i și j . În cazul în care muchiile au ponderi unitare, c_{ij} indică numărul de muchii care conectează i și j . Rezultatul algoritmului de partiționare este o pereche de seturi (blocuri) A și B astfel încât $|A| = |B| = n$, $A \cap B = \emptyset$, iar setul de tăietură are o dimensiune cât mai mică. Această dimensiune este măsurată prin T ,

$$T = \sum_{a \in A, b \in B} c_{ab} \quad (3.6)$$

Algoritmul pornește de la o partiție inițială astfel încât $|A| = |B| = n$ și $A \cap B = \emptyset$. Fie $\vec{P} = \{\vec{A}, \vec{B}\}$ partiția optimă, iar $P = \{A, B\}$ partiția curentă. Pentru a se obține \vec{P} din P , trebuie să se interschimbe un subset $X \subseteq A$ cu un subset $Y \subseteq B$, astfel încât:

- (1) $|X| = |Y|$
- (2) $X = A \cap B^*$
- (3) $Y = A^* \cap B$

Această interschimbare este ilustrată în Figura 3.2.




Figura 3.2. Partiția inițială și cea optimă.

Problema identificării subseturilor X și Y este la fel de dificilă cu cea a determinării partiției $\tilde{P} = \{A^*, B^*\}$. Kernighan și Lin au propus o metodă euristică pentru a aproxima X și Y . Se va analiza mai întâi efectul interschimbării unui singur nod din blocul A cu un alt nod din blocul B .

Considerăm un nod oarecare a din blocul A . Contribuția nodului a la setul de tăietură se numește costul extern al lui a , sau E_a , și este numărul muchiilor dintre nodul $a \in A$ și care se termină în B :

$$E_a = \sum_{v \in B} c_{av} \quad (3.7)$$

Similar, se poate defini costul intern I_a al nodului $a \in A$ ca fiind:

$$I_a = \sum_{v \in A} c_{av} \quad (3.8)$$

Dacă nodul a se mută din blocul A în blocul B , dimensiunea setului de tăietură va crește cu o valoare I_a și va scădea cu o valoare E_a . Câștigul în urma mutării este deci $E_a - I_a$, valoare care se numește valoare D a nodului a :

$$D_a = E_a - I_a \quad (3.9)$$

Efectul interschimbării a două noduri între blocurile A și B este caracterizat de lema 3.4.1.1 [146].

Lema 3.4.1.1. Dacă două elemente $a \in A$ și $b \in B$ sunt interschimbate, reducerea costului este dată de:

$$g_{ab} = D_a + D_b - 2c_{ab} \quad (3.10)$$

Interschimbarea a două noduri afectează valorile D ale tuturor nodurilor care sunt conectate la oricare din nodurile interschimbate. Lema 3.4.1.2 indică modul de actualizare a valorilor D ale nodurilor rămase după ce două noduri a și b au fost interschimbate.

Lema 3.4.1.2. Dacă două elemente $a \in A$ și $b \in B$ sunt interschimbate, noile valori D , indicate prin D' , sunt date de:

$$D'_x = D_x + 2c_{xa} - 2c_{xb}, \quad \forall x \in A - \{a\} \quad (3.11)$$

$$D'_y = D_y + 2c_{yb} - 2c_{ya}, \quad \forall y \in B - \{b\} \quad (3.12)$$

Presupunem că există o partiție inițială $\{A, B\}$ de câte n elemente fiecare. Kernighan și Lin au utilizat Lema 1 și Lema 2 și au elaborat o procedură de tip greedy

pentru a identifica două subseturi $X \subseteq A$ și $Y \subseteq B$, de cardinalități egale, astfel încât în urma interschimbării acestora costul partiției este îmbunătățit. X și Y pot fi vide, indicând în acest caz faptul că partiția curentă nu mai poate fi îmbunătățită.

În cursul procedurii, se calculează câștigurile interschimbării oricăror două module $a \in A$ și $b \in B$. Este selectată perechea (a_1, b_1) care conduce la câștigul maxim g_1 , iar elementele a_1 și b_1 sunt blocate pentru a nu fi luate în considerare la următoarele interschimbări. Valorile D ale celulelor libere rămase sunt actualizate, iar câștigurile sunt recalculat. Apoi este selectată și blocată a o doua pereche (a_2, b_2) cu câștigul maxim g_2 . De notat că g_2 este câștigul interschimbării a_2 cu b_2 după ce a_1 a fost deja interschimbabil cu b_1 . Astfel, câștigul interschimbării perechii (a_1, b_1) urmat de interschimbarea (a_2, b_2) este $G_2 = g_1 + g_2$. Procesul continuă selectând $(a_1, b_1), (a_2, b_2), \dots, (a_i, b_i) \dots (a_n, b_n)$, câștigurile corespunzătoare fiind $g_1, g_2, \dots, g_i, \dots, g_n$. Evident, $G = \sum_{i=1}^n g_i = 0$, deoarece aceasta presupune interschimbarea tuturor elementelor din A cu cele din B , rezultând partiția inițială. În general, câștigul interschimbării primelor k perechi $(a_1, b_1), (a_2, b_2), \dots, (a_k, b_k)$, $1 \leq k \leq n$ este $G_k = \sum_{i=1}^k g_i$. Dacă nu există un k astfel ca $G_k > 0$ atunci partiția curentă nu poate fi îmbunătățită; în caz contrar se alege valoarea k care maximizează G_k și se efectuează interschimbarea $\{a_1, a_2, \dots, a_k\}$ cu $\{b_1, b_2, \dots, b_k\}$ în mod permanent.

Procedura de îmbunătățire a unei partiții, indicată mai sus, constituie un singur pas al algoritmului Kernighan-Lin. Partiția obținută după pasul i constituie partiția inițială pentru pasul $i + 1$. Iterațiile se termină atunci când $G_k \leq 0$, deci nu se mai pot obține îmbunătățiri suplimentare prin interschimbarea perechilor. Algoritmul este descris în Figura 3.3.

```

Algorithm KL;
begin
Pas 1.  $V =$  setul a  $2n$  elemente;
      *  $\{A, B\}$  este partiția inițială astfel încât
       $|A| = |B|$ ,  $A \cap B = \emptyset$  și  $A \cup B = V$ ;
Pas 2. Se calculează  $D_v$  pentru fiecare  $v \in V$ ;
      lista  $\leftarrow \emptyset$ ;  $i \leftarrow 1$ ;
       $A' = A$ ;  $B' = B$ ;
Pas 3. Se alege  $a_i \in A'$ ,  $b_i \in B'$  care maximizează  $g_i = D_{a_i} + D_{b_i} - 2c_{a_i b_i}$ ;
      Se adaugă perechea  $(a_i, b_i)$  la lista;
       $A' = A' - \{a_i\}$ ;  $B' = B' - \{b_i\}$ ;
Pas 4. if  $A'$  și  $B'$  sunt ambele vide then goto Pas 5
      else
          Se recalculează valorile  $D$  pentru  $A' \cup B'$ ;
           $i \leftarrow i + 1$ ; goto Pas 3;
      endif;
Pas 5. Se determină  $k$  pentru a maximiza suma parțială  $G = \sum_{i=1}^n g_i$ ;
      if  $G > 0$  then
          Se mută  $X = \{a_1, \dots, a_k\}$  în  $B$  și  $Y = \{b_1, \dots, b_k\}$  în  $A$ ;
          goto Pas 2
      else STOP
      endif
end.

```

Figura 3.3. Algoritmul Kernighan-Lin pentru bipartiționare.

Complexitatea algoritmului Kernighan-Lin este $O(pn^2 \log n)$, unde p este numărul de iterații ale procedurii de îmbunătățire. Experimente asupra unor circuite de

dimensiuni mari au indicat faptul că p nu crește cu n . Astfel, complexitatea algoritmului este de $O(n^2 \log n)$ [146].

Complexitatea etapei de selecție a perechilor poate fi îmbunătățită prin parcurgerea listei nesortate de valori D și selectarea a și b care maximizează D_a și D_b . Deoarece aceasta se poate realiza într-un timp liniar, complexitatea algoritmului se reduce la $O(n^2)$. Această metodă este potrivită pentru matrici rare unde probabilitatea ca $c_{ab} > 0$ este redusă. Aceasta reprezintă însă o aproximare a procedurii de selecție greedy, și poate genera o soluție diferită comparativ cu selecția greedy.

3.4.2 Variante ale algoritmului Kernighan-Lin

Algoritmul Kernighan-Lin poate fi extins pentru a rezolva și alte cazuri ale problemei de partiționare. O parte din acestea sunt prezentate în continuare.

Blocuri cu dimensiuni inegale. Pentru partiționarea unui graf $G = (V, E)$ cu $2n$ vârfuri în două subgrafuri cu dimensiuni inegale n_1 și n_2 , $n_1 + n_2 = 2n$, se poate utiliza procedura următoare:

1. Se divide setul V în două subseturi A și B , una conținând $MIN(n_1, n_2)$ vârfuri, iar cealaltă conținând $MAX(n_1, n_2)$ vârfuri. Această diviziune se poate efectua în mod arbitrar.
2. Se aplică algoritmul din Figura 3.3 începând de la Pasul 2, dar se restricționează numărul maxim de vârfuri care pot fi interschimbate într-un pas la $MIN(n_1, n_2)$.

O altă soluție posibilă a acestei probleme este următoarea. Presupunând că $n_1 < n_2$, se divide V astfel încât există cel puțin n_1 vârfuri în blocul A și cel mult n_2 vârfuri în blocul B , utilizând procedura de mai jos.

1. Se divide setul V în blocurile A cu n_1 vârfuri și B cu n_2 vârfuri.
2. Se adaugă $n_2 - n_1$ vârfuri fictive blocului A . Aceste vârfuri nu au conexiuni cu graful original.
3. Se aplică algoritmul din Figura 3.3 începând de la Pasul 2.
4. Se elimină vârfurile fictive.

Elemente cu dimensiuni inegale. Pentru a genera o bipartiție a unui graf ale cărui vârfuri au dimensiuni inegale, se poate proceda în modul următor:

1. Se presupune că elementul cu dimensiune minimă are dimensiunea unitară.
2. Se înlocuiește fiecare element de dimensiune s cu s vârfuri complet conectate cu muchii de pondere infinită.
3. Se aplică algoritmul din Figura 3.3.

Partiționare cu k căi. Se presupune că graful are $k \cdot n$ vârfuri, $k > 2$, și este necesară generarea unei partiții cu k căi, fiecare cu n elemente.

1. Se începe cu o partiție aleatoare de k seturi cu n vârfuri fiecare.
2. Se aplică procedura de bipartiționare pentru fiecare pereche de partiții.

Optimalitatea perechilor de partiții este doar o condiție necesară a optimalității în cazul problemei de partiționare cu k căi. Uneori va fi necesară o interschimbare complexă de trei sau mai multe elemente din trei sau mai multe subseturi pentru a se obține soluția optimă globală. Deoarece există $\binom{k}{2}$ perechi care trebuie luate în considerare, complexitatea pentru un pas al procedurii executate pentru toate perechile

este $\binom{k}{2}n^2 = O(k^2n^2)$. În general, vor fi necesari mai mulți pași, deoarece atunci când o anumită pereche de partiții este optimizată, optimalitatea acestor partiții față de altele se poate modifica.

3.4.3 Euristică Fiduccia-Mattheyses

Algoritmul Kernighan-Lin partiționează un circuit modelat ca un graf în două blocuri A și B astfel încât costul muchiilor tăiate de partiție să fie minimizat. În cazul conexiunilor cu două puncte, numărul muchiilor tăiate de partiție este egal cu numărul conexiunilor tăiate. În cazul conexiunilor multipunct, situația este însă diferită. Figura 3.4 ilustrează un circuit și reprezentarea sa sub forma unui graf. Dacă se partiționează graful în două blocuri $A = \{1, 2, 3\}$ și $B = \{4, 5, 6\}$, numărul muchiilor tăiate este egal cu patru, în timp ce sunt necesare doar trei conexiuni între celulele blocului A și celulele blocului B . De aceea, reducerea numărului de conexiuni tăiate este un obiectiv mai realist decât reducerea numărului de muchii tăiate.

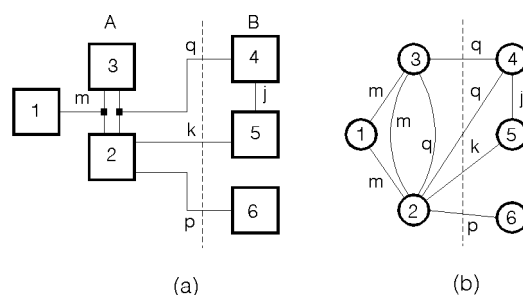


Figura 3.4. (a) Ilustrarea tăieturii conexiunilor. (b) Ilustrarea tăieturii muchiilor.

Fiduccia și Mattheyses au elaborat o euristică iterativă care ia în considerare atât conexiunile multipin, cât și dimensiunile elementelor de circuit. Contribuția acestora constă în permiterea mutării unui singur nod la un moment dat între cele două subseturi ale partiției, o analiză și o implementare atentă a efectului mutării unui singur nod asupra valorilor D ale altor noduri, și utilizarea unei structuri de date eficiente pentru a se evita căutarea inutilă a nodului care va fi mutat în etapa următoare [189].

Euristică Fiduccia-Mattheyses este o tehnică utilizată pentru a găsi soluția la următoarea problemă de bipartiționare: Fiind dat un circuit constând din C celule conectate printr-un set de N conexiuni, problema este de a partiționa circuitul C în două blocuri A și B astfel încât numărul conexiunilor care au celule în ambele blocuri este minimizat și este satisfăcut factorul de echilibru r [76]. Se prezintă în continuare principalele diferențe și similarități între euristicele Kernighan-Lin și Fiduccia-Mattheyses [146].

1. Spre deosebire de euristică Kernighan-Lin în care este selectată pentru inter schimbare o pereche de celule, câte una din fiecare bloc, în fiecare pas, în cazul euristicii Fiduccia-Mattheyses este selectată la un moment dat o singură celulă, din oricare bloc, pentru a fi mutată în blocul complementar.
2. Euristică Kernighan-Lin partiționează un graf în două blocuri astfel încât costul muchiilor tăiate este minim, în timp ce euristică Fiduccia-Mattheyses are ca scop reducerea costului conexiunilor tăiate de partiție.
3. Euristică Fiduccia-Mattheyses este similară cu cea Kernighan-Lin în ceea ce privește selecția celulelor. În locul câștigului datorat interschimbării a două celule este calculat câștigul datorat mutării unei singure celule dintr-un bloc în

altul. După selecția unei celule, aceasta este blocată pentru restul pasului respectiv. Numărul total de celule care sunt mutate este dat de secvența cea mai bună de mutări c_1, c_2, \dots, c_k . În cazul euristicii Kernighan-Lin, într-un pas sunt interschimbate primele cele mai bune k perechi.

4. Datorită faptului că este mutată o singură celulă, poate apare un dezechilibru între cele două blocuri. De aceea, euristica Fiduccia-Mattheyses generează partiții echilibrate din punct de vedere al dimensiunii. Factorul de echilibru r este specificat de utilizator și este definit astfel: $r = \frac{|A|}{|A|+|B|}$, unde $|A|$ și $|B|$ sunt dimensiunile blocurilor partitionate A și B .
5. Anumite celule pot fi blocate inițial într-una din partiții.
6. Complexitatea în timp a euristicii Fiduccia-Mattheyses este liniară. În practică este necesar un număr mic de pași, rezultând un algoritm rapid.

Se prezintă în continuare unele definiții și termeni utilizați pentru descrierea algoritmului.

Fie $p(j)$ numărul pinilor celulei j , și fie $s(j)$ dimensiunea celulei j , pentru $j = 1, 2, \dots, C$. Dacă V este setul celor C celule, atunci $|V| = \sum_{i=1}^C s(i)$.

Starea de tăietură a unei conexiuni: O conexiune este tăiată dacă are celule în ambele blocuri, și este netăiată în caz contrar. Se utilizează o variabilă pentru a indica starea unei conexiuni.

Setul de tăietură al partiției: Acest set al unei partiții este cardinalitatea setului tuturor conexiunilor cu starea tăiată.

Câștigul celulei: Câștigul $g(i)$ al unei celule i este numărul de conexiuni cu care s-ar reduce setul de tăietură dacă celula i ar fi mutată.

Criteriu de echilibru: Pentru a se evita migrarea tuturor celulelor într-un bloc, este menținut un criteriu de echilibru. O partiție (A, B) este echilibrată dacă:

$$r \times |V| - s_{max} \leq |A| \leq r \times |V| + s_{max} \quad (3.13)$$

unde $|A| + |B| = |V|$, iar $s_{max} = \text{Max}[s(i)]$, $i \in A \cup B = V$.

Celulă de bază: Celula selectată pentru mutarea dintr-un bloc în altul este numită *celulă de bază*. Aceasta este celula cu câștigul maxim și cea a cărei mutare nu va viola criteriul de echilibru.

Distribuția unei conexiuni: Distribuția unei conexiuni n este o pereche $(A(n), B(n))$, unde (A, B) este o partiție arbitrară, $A(n)$ este numărul de celule ale conexiunii n care sunt în A , iar $B(n)$ este numărul de celule ale conexiunii n care sunt în B .

Conexiune critică: O conexiune este critică dacă are o celulă care, dacă este mutată, va schimba starea sa de tăietură. Aceasta se întâmplă dacă și numai dacă $A(n)$ este fie 0 sau 1, sau $B(n)$ este fie 0 sau 1.

Algoritmul este prezentat în Figura 3.5.

Înainte de fiecare mutare, trebuie găsită celula cu valoarea D maximă dintr-una din cele două subseturi ale partiției curente. Pentru a evita căutarea unei asemenea celule, algoritmul FM utilizează o tabelă pentru fiecare subset al partiției, a cărei intrare k este o listă dublu înălțurată de celule din subsetul a cărei valoare D este k , și un pointer la intrarea cu valoarea D maximă pentru fiecare din cele două tabele. În aceste tabele sunt păstrate numai celulele care nu au fost mutate în pasul curent. Astfel, utilizând aceste tabele, o celulă cu valoarea D maximă din oricare subset al partiției poate fi găsită într-un timp constant. Pentru a se permite actualizarea celor două tabele, fiecare celulă are un pointer la locația sa din tabela corespunzătoare. Dacă câștigul D_i al celulei i s-a modificat din cauza mutării unei alte celule, atunci se utili-

zează pointerul celulei i pentru a elimina celula i din lista sa curentă din tabelă, și pentru adăugarea în lista care corespunde noului câștig D_i al celulei. Această actualizare necesită numai un timp constant datorită utilizării listelor dublu înlănțuite. Utilizând această structură de date, Fiduccia și Mattheyses au arătat că timpul de execuție al unui pas al algoritmului este liniar cu numărul total de pini al circuitului [189].

```

Algorithm FM;
begin
Pas 1. Se calculează câștigul tuturor celulelor;
Pas 2.  $i = 1$ ;
      Este selectată celula de bază și este notată cu  $c_i$ ;
      if nu există celulă de bază then exit; endif;
      O celulă de bază este cea care
          (i) are câștigul maxim;
          (ii) satisface criteriul de echilibru;
      if egalitate then se utilizează Criteriul de dimensiune sau
          Numărul conexiunilor interne;
      endif;
Pas 3. Se blochează celula  $c_i$ ;
      Se actualizează câștigul celulelor conexiunilor critice afectate;
Pas 4. if celule_libre  $\neq \emptyset$  then
       $i = i + 1$ ;
      Este selectată următoarea celulă de bază  $c_i$ ;
      endif;
      if  $c_i \neq \emptyset$  then goto Pas 3 endif;
Pas 5. Se selectează secvența cea mai bună de mutări  $c_1, c_2, \dots, c_k$  ( $1 \leq k \leq i$ )
      astfel încât  $G = \sum_{j=1}^k g_j$  este maxim;
      if  $G \leq 0$  then exit; endif;
Pas 6. Toate cele  $k$  mutări devin permanente;
      Se deblochează toate celulele;
      goto Pas 1
end.

```

Figura 3.5. Algoritmul de bipartiționare Fiduccia-Mattheyses.

3.4.4 Partiționarea prin metoda călirii simulate

Călirea simulată este o tehnică iterativă utilizată pe scară largă pentru rezolvarea diferitelor probleme combinatoriale de optimizare. A fost utilizată pentru majoritatea problemelor CAD, inclusiv pentru partiționare. Este o euristică adaptivă care aparține clasei algoritmilor stohastici. Această euristică a fost introdusă pentru prima dată de Kirkpatrick, Gelatt și Vecchi [102].

Euristica de călire simulată se inspiră din procesul de răcire controlată a metalelor topite pentru a se obține o structură cristalină corespunzătoare. Dacă se compară optimizarea cu procesul de călire, se poate realiza o analogie între obținerea optimului global și obținerea structurii cristaline dorite.

Orice problemă de optimizare combinatorială poate fi discutată în termenii unui *spațiu al stărilor*. O stare este o configurație a obiectelor combinatoriale implicate. Din numărul mare de configurații, numai unele din acestea corespund optimului global.

O metodă de îmbunătățire iterativă pornește de la o anumită stare dată, și examinează o vecinătate locală a stării pentru a căuta soluții mai bune. O vecinătate locală a unei stări S este setul tuturor stărilor care pot fi obținute din S prin unele modificări

ale stării S . De exemplu, dacă S reprezintă o bipartiție a unui graf, setul tuturor partițiilor care se pot obține prin interschimbarea a două noduri din cadrul partiției reprezintă o vecinătate locală.

Metodele iterative de partiționare prezentate anterior sunt de tip greedy, deci sunt permise numai perturbațiile care îmbunătățesc soluția curentă. Astfel aceste metode pot obține soluții optime locale. Euristică de călire simulată încearcă remedierea acestei situații, acceptând și perturbații care conduc la obținerea unei soluții inferioare celei curente, existând astfel posibilitatea de a evita obținerea unei soluții optime locale.

Algoritmul de călire simulată este prezentat în Figura 3.6.

Partea principală a algoritmului este procedura *Metropolis*, care simulează procesul de călire la o temperatură dată T . Această procedură constă în generarea unui lanț Markov de stări, ale căror energii ar avea o distribuție Boltzmann dacă lanțul ar avea o lungime infinită. Deoarece lanțul este de lungime finită, distribuția rezultată va fi doar apropiată de distribuția Boltzmann. Pe lângă temperatură, procedura *Metropolis* mai are ca intrări soluția curentă S care va fi îmbunătățită, și valoarea M , care este durata de timp în care este aplicată călirea la temperatura T . Procedura *SA* apelează procedura *Metropolis* la diferite temperaturi descrescătoare. Temperatura este redusă lent de la valoarea T_0 în progresie geometrică, în funcție de parametrul α . Durata de timp a procesului de călire la o anumită temperatură este mărită gradat pe măsură ce temperatura este micșorată. Aceasta se realizează utilizând parametrul $\beta > 0$.

```

Algorithm SA ( $S_0, T_0, \alpha, \beta, M, TimpMax$ );
    /*  $S_0$  este soluția inițială */
    /*  $T_0$  este temperatura inițială */
    /*  $\alpha$  este rata de răcire */
    /*  $\beta$  este o constantă */
    /*  $TimpMax$  este timpul total permis pentru procesul de călire */
    /*  $M$  reprezintă timpul până la următoarea actualizare a parametrilor */

begin
     $T = T_0$ ;
     $S = S_0$ ;
     $Timp = 0$ ;
    repeat
        Metropolis ( $S, T, M$ );
         $Timp = Timp + M$ ;
         $T = \alpha \times T$ ;
         $M = \beta \times M$ 
    until ( $Timp \geq TimpMax$ )

end.

```

Figura 3.6. Algoritmul de călire simulată.

Procedura *Metropolis* este prezentată în Figura 3.7. Aceasta utilizează procedura *Vecin* pentru a genera o vecinătate locală *NewS* a unei soluții date S . Funcția *Cost* returnează costul unei soluții date S . În cazul în care costul noii soluții *NewS* este mai redus decât costul soluției curente S , noua soluție este acceptabilă, și se va seta $S = NewS$. Dacă noua soluție are un cost mai mare comparativ cu soluția originală S , *Metropolis* va accepta noua soluție într-un mod probabilistic. Se generează un număr aleator între 0 și 1; dacă acest număr este mai mic decât $e^{-\Delta h/T}$, unde Δh este diferența între costuri, iar T este temperatura, soluția inferioară calitativ va fi acceptată. Acest criteriu pentru acceptarea noii soluții este numit *criteriu Metropolis*. Procedura *Metropolis* generează și examinează M soluții.

```

Algorithm Metropolis ( $S, T, M$ );
begin
  repeat
     $NewS = Vecin(S)$ ;
     $\Delta h = (Cost(NewS) - Cost(S))$ ;
    if  $((\Delta h < 0)$  or  $(random < e^{-\Delta h/T}))$  then  $S = New$  endif;
     $M = M - 1$ 
  until  $(M = 0)$ 
end.

```

Figura 3.7. Procedura Metropolis.

Probabilitatea ca o soluție inferioară să fie acceptată de procedura *Metropolis* este dată de $P(random < e^{-\Delta h/T})$. Se presupune că generarea numerelor aleatoare urmărește o distribuție uniformă. În acest caz, probabilitatea se reduce la $e^{-\Delta h/T}$. Deoarece s-a presupus că soluția *NewS* este inferioară comparativ cu *S*, $\Delta h > 0$. La temperaturi foarte înalte, de exemplu $T \rightarrow \infty$, probabilitatea de sus se apropie de 1. Din contră, atunci când $T \rightarrow 0$, probabilitatea $e^{-\Delta h/T}$ se apropie de 0.

Pentru a se utiliza călirea simulată la rezolvarea problemei de bipartiționare, trebuie să se formuleze mai întâi o funcție de cost care să reflecte atât criteriul de echilibru, cât și ponderea setului de tăietură. Pentru o partiție dată (A, B) a circuitului, se definește

$$Dezechilibru(A, B) = \sum_{v \in A} s(v) - \sum_{v \in B} s(v) \quad (3.14)$$

$$Pondere\ set\ de\ tăietură(A, B) = \sum_{n \in \psi} w_n \quad (3.15)$$

unde $s(v)$ este dimensiunea vârfului v , w_n este ponderea conexiunii n , iar ψ este setul conexiunilor cu terminale atât în A cât și în B .

$$Cost(A, B) = W_c * Pondere\ set\ de\ tăietură(A, B) + W_s * Dezechilibru(A, B) \quad (3.16)$$

W_c și W_s sunt constante în domeniul $[0, 1]$ care indică importanța relativă a minimizării setului de tăietură, respectiv a echilibrului. De observat că, spre deosebire de algoritmul Kernighan-Lin, restricția de echilibru este parte a funcției de cost. Dacă algoritmul se oprește la o minimă locală, partiția obținută poate fi dezechilibrată.

Cea mai simplă funcție de vecinătate se obține prin interschimbarea unei perechi de elemente, câte una din fiecare partiție. Se poate selecta de asemenea un subset de elemente din fiecare partiție pentru a fi interschimbate. O altă posibilitate este de a se selecta acele elemente a căror contribuție la costul extern este ridicată, sau cele care sunt conectate intern cu cel mai mic număr de vârfuri.

Studii teoretice au arătat că prin metoda călirii simulate se poate obține soluția optimă dacă sunt satisfăcute anumite condiții [189]. În practică, aceste condiții implică un număr infinit de iterații. Se utilizează diferite euristici pentru a reduce timpul de execuție al algoritmului. Totuși, algoritmul de călire simulată rămâne lent din punct de vedere computațional, și mai puțin eficient comparativ cu anumite euristici specifice diferitelor probleme.

3.4.5 Partiționarea prin tăietura proporțională

Fiind dat un circuit $N = (V, E)$, unde V este setul de noduri, iar E este setul de muchii, fie c_{ij} capacitatea unei muchii care conectează nodul i cu nodul j . (A, A') indică o tăietură care separă un set de noduri A de $A' = V - A$. Capacitatea acestei tăie-

turi este egală cu $C_{AA'} = \sum_{i \in A} \sum_{j \in A'} c_{ij}$. Proporția acestei tăieturi este definită prin raportul

$$R_{AA'} = \frac{C_{AA'}}{|A| \times |A'|} \quad (3.17)$$

unde $|A|$ și $|A'|$ reprezintă cardinalitatea subseturilor A și A' . Această metrică din ecuația 3.17 a fost propusă de Wei și Cheng [175] și s-a dovedit o funcție obiectiv de succes pentru numeroase aplicații. Numărătorul reprezintă criteriul de tăietură minimă, în timp ce numitorul favorizează o partiție echilibrată, deoarece $|A| \times |A'|$ este maxim atunci când $|A| = |A'|$. Tăietura proporțională este tăietura care generează proporția minimă $R_{AA'}$ dintre toate tăieturile circuitului, deci $\min_A (C_{AA'} / |A| \times |A'|)$ ($A \subset V$ și $A \neq \emptyset, A' \neq \emptyset$).

Metoda de partiționare prin tăietura proporțională are tendința de a identifica grupările naturale din circuit [50], [146], [175]. Această proprietate poate fi interpretată printr-un model de graf aleator. Figura 3.8 ilustrează un graf aleator cu distribuție uniformă cu n noduri. Probabilitatea de a exista o muchie care să conecteze fiecare pereche de noduri este egală cu aceeași valoare f .




Figura 3.8. Un graf aleator cu n noduri și probabilitate f .

Considerăm o tăietură CUT_1 în Figura 3.8, care partiționează circuitul în două submulțimi A și A' cu dimensiuni comparabile de $\alpha \times n$ noduri, respectiv $(1 - \alpha) \times n$ noduri, unde $0 < \alpha < 1$. Capacitatea probabilă $C_{AA'}$ a tăieturii CUT_1 este egală cu probabilitatea f multiplicată cu numărul posibil de muchii între A și A' :

$$P(C_{AA'}) = f \times |A| \times |A'| = f \times \alpha \times (1 - \alpha) \times n^2 \quad (3.18)$$

Pe de altă parte, dacă o altă tăietură CUT_2 în Figura 3.8 separă un singur nod s de restul nodurilor, numărul probabil de muchii tăiate de CUT_2 este:

$$P(C_{\{s\}\{s'\}}) = f \times (n - 1) \quad (3.19)$$

Pe măsură ce n se apropie de infinit, valoarea din ecuația 3.18 devine mult mai mare decât cea din ecuația 3.19. Aceasta este o explicație a motivului pentru care metoda de flux maxim și tăietură minimă are tendința să genereze submulțimi de dimensiuni foarte diferite, pentru care valoarea de tăietură este minimă [175]. De aceea, se propune raportul $(C_{AA'} / |A| \times |A'|)$ pentru a reduce acest efect.

Ca o consecință, valoarea probabilă a acestui raport este o constantă pentru diferite tăieturi:

$$P(R_{AA'}) = P\left(\frac{C_{AA'}}{|A| \times |A'|}\right) = \frac{f \times |A| \times |A'|}{|A| \times |A'|} = f \quad (3.20)$$

Deci, dacă muchiile grafului sunt distribuite uniform, toate tăieturile au aceeași valoare a raportului de tăietură. Cu alte cuvinte, în grafurile aleatoare cu distribuție uniformă nu are importanță alegerea tăieturilor. Însă, într-un circuit general, diferite

tăieturi generează rapoarte diferite. Tăieturile care trec prin grupuri slab conectate le corespund raporturi mai mici.

Ca și alte probleme de partiționare, găsirea tăieturii proporționale într-un circuit aparține clasei problemelor NP-complete. De aceea, este necesară o euristică rapidă pentru a putea fi utilizată în cazul circuitelor VLSI complexe. Wei și Cheng [175] au elaborat o asemenea euristică, bazată pe algoritmul Fiduccia-Mattheyses [76], datorită eficienței acestuia. Algoritmul pentru tăietura proporțională constă din trei faze principale: 1) inițializare, 2) deplasare iterativă, și 3) interschimbarea grupurilor. Aceste faze sunt prezentate în continuare.

Inițializare. În această fază, restricția privind dimensiunea subseturilor este eliminată. Algoritmul stabilește în mod dinamic propriile subseturi care sunt apropiate de grupările din circuit. Este selectat în mod aleator un modul s ca nucleu, iar apoi un alt modul t aflat la capătul căii celei mai lungi, prin căutare în lățime începând cu modulul s . Grupul va conține la început fie modulul s , fie modulul t , și de fiecare dată se adaugă la acest grup cel mai bun candidat, până când se epiuzează toate modulele (exceptând al doilea nucleu). Deoarece la fiecare pas de adăugare rezultă o nouă valoare a raportului, se memorează fiecare valoare chiar dacă ea este mai mare decât precedentă, astfel încât algoritmul poate evita minimele locale. Tăietura care determină raportul minim formează o grupare inițială din circuit. Dacă circuitul are un set de M module, procedura de inițializare poate fi descrisă astfel:

1. Se alege în mod aleator un modul s . Se determină al doilea modul t la capătul căii celei mai lungi prin căutare în lățime începând de la modulul s . Fie $X = \{s\}$ și $Y = M - \{s, t\}$.
2. Se alege un modul i din Y a cărui mutare în X va genera cel mai bun raport față de toate celelalte module concurente. Se mută modulul i din Y în X ; se actualizează $X = X \cup \{i\}$ și $Y = Y - \{i\}$.
3. Se repetă pasul 2 până când $Y = \emptyset$.
4. Se repetă pașii 2 și 3 cu $X = \{t\}$ și $Y = M - \{s, t\}$ până când $Y = \emptyset$.
5. Tăietura cu raportul minim care s-a găsit în timpul procedurii formează partiția inițială.

Deplasare iterativă. Se presupune că modulul nucleu s este fixat în partea stângă, iar modulul t în partea dreaptă. Se definește o operație de deplasare la dreapta (stânga) ca fiind deplasarea modulelor cu valoarea cea mai bună a raportului de tăietură de la modulul s (t) către modulul t (s).

După generarea unei partiții inițiale, se repetă operațiile de deplasare în direcția opusă pentru a se obține o îmbunătățire suplimentară. Procedura este aplicată în mod iterativ ultimei partiții. Dacă direcția partiționării inițiale este de la s la t , procesul de deplasare începe cu următoarele operații.

1. Se repetă operațiile de deplasare la dreapta până la epuizarea tuturor modulelor.
2. Se alege valoarea minimă a raportului obținut în pasul 1. Dacă noua valoare a raportului este mai mică față de pasul 1, tăietura care produce acest raport formează o nouă partiție de început; în caz contrar, se returnează partiția precedentă și procesul se termină.
3. Se repetă pașii 1 și 2 cu operațiile de deplasare la stânga.
4. Se repetă pașii 1 - 3.

Interschimbarea grupurilor. După terminarea deplasării iterative, se obține o partiționare minimă locală în sensul că mutarea unui singur modul din subsetul său

curent în celălalt set nu poate reduce valoarea raportului de tăietură. Pentru a se obține îmbunătățiri suplimentare, se utilizează o tehnică de interschimbare a grupurilor.

Se definește câștigul raportului $r(i)$ a unui modul i modificarea raportului dacă modulul i (cu excepția celor două nuclee s și t) ar fi mutat din subsetul său curent în celălalt subset. Procesul de interschimbare a grupurilor este următorul.

1. Se calculează câștigul raportului $r(i)$ pentru fiecare modul i , și se setează toate modulele în starea "neblocată".
2. Se selectează un modul neblocat i cu câștigul raportului maxim.
3. Se mută modulul i în celălalt subset, și se blochează.
4. Se actualizează câștigurile raporturilor pentru restul modulelor afectate și ne-blocate.
5. Se repetă pașii 2 - 4 până când toate modulele vor fi blocate.
6. Dacă cel mai mare câștig al raportului care s-a acumulat în timpul acestui proces este pozitiv, se interschimbă grupul de module corespunzătoare câștigului maxim, și se continuă cu pasul 1; în caz contrar, se returnează partiția precedentă și procedura se termină.

Implementarea tehnicii de interschimbare a grupurilor se bazează pe structura de date propusă de Fiduccia și Mattheyses [76]. Fie (A, A') tăietura rezultată din deplasarea iterativă. Câștigul raportului pentru mutarea modulului i cu dimensiunea $s(i)$ din A' în A este exprimat prin $r(i) = g(i) / [|A| + s(i)] \times |A'| - s(i)$, unde $g(i)$ este decrementul numărului de conexiuni tăiate dacă modulul i ar fi mutat în celălalt subset. Deoarece fiecare $g(i)$ este un întreg în domeniul $-p(i)$ la $p(i)$, unde $p(i)$ este numărul de pini din modulul i , structura de date poate fi reprezentată printr-un tabel a cărei intrare k conține o listă dublu înlănțuită de module cu valorile $g(i)$ egale cu k la un moment dat. Se păstrează două asemenea structuri de date, câte una pentru fiecare subset.

Faza de inițializare și cea de deplasare iterativă pot fi implementate ca și cazuri speciale ale interschimbării grupurilor. Primele două faze realizează deplasarea modulelor într-o singură direcție, în timp ce interschimbarea grupurilor are flexibilitatea de a muta modulele în ambele direcții.

Interschimbarea grupurilor care utilizează structura de date descrisă în [76] are complexitatea $O(P)$, unde P este numărul de pini. Găsirea căii celei mai lungi prin căutare în lățime are de asemenea complexitatea $O(P)$, ca și fazele de inițializare și deplasare iterativă [175]. Astfel, complexitatea întregului algoritm rămâne liniară cu numărul de pini.

În algoritmul prezentat anterior a fost eliminată restricția asupra dimensiunii subseturilor, metoda furnizând automat subseturile care sunt grupuri naturale în cadrul circuitului. Astfel, există o libertate deplină în ceea ce privește dimensiunile subseturilor rezultate. Uneori însă este necesar să se impună o restricție de dimensiune asupra subseturilor rezultate datorită limitărilor fizice ale circuitelor.

Pentru a se realiza o partiționare cu restricții de dimensiune, se specifică o limită superioară a dimensiunii subsetului. La fiecare aplicare a algoritmului original de tăietură proporțională, se obțin două subseturi. Dacă dimensiunea unuia din subseturi este mai mare decât limita superioară, se elimină subsetul mai mic și se continuă aplicarea algoritmului asupra subsetului rămas în circuitul redus până când dimensiunile tuturor subseturilor sunt mai mici decât limita superioară.

Ultimul pas este repunerea grupurilor mici care au fost eliminate și distribuirea lor în subseturile potrivite. Se poate considera subsetul mai mare din ultima partiționare ca fiind un subset, și toate celelalte subseturi generate în timpul procesului ca un alt subset. Algoritmul aplică o iterație a operațiilor de deplasare la stânga/dreapta pentru a muta un anumit număr de module din subsetul mai mare în subsetul mai

mic, și găsește tăietura proporțională cea mai bună care satisface restricția de dimensiune. Calitatea partiționării poate fi sacrificată pentru a se putea satisface restricția de dimensiune.

Fiind dat un circuit N și un întreg lim_sup , algoritmul cu restricție de dimensiune poate fi descris astfel [175]:

1. Se inițializează $\Psi = \{N\}$.
2. Se alege $N' \in \Psi$ astfel ca $|N'| = \max |A_i|$, $A_i \in \Psi$. Se setează $\Psi = \Psi - \{N'\}$. Se aplică algoritmul de tăietură proporțională pentru a obține o tăietură (A, A') , unde $N' = A \cup A'$, presupunând $|A| \geq |A'|$.
3. Dacă ($|A| \leq lim_sup$), se continuă cu pasul 4; în caz contrar, fie $\Psi = \Psi \cup \{A, A'\}$, și se continuă cu pasul 2.
4. Fie A un subset, iar $A'' = N - A$ al doilea subset. Se execută o iterație a operațiilor de deplasare la dreapta/stânga între A și A'' pentru a găsi tăietura proporțională cea mai bună care satisface restricția de dimensiune.
5. Se returnează rezultatul final.

Comparativ cu algoritmul Fiduccia-Mattheyses, rezultatele experimentelor efectuate în [175] arată că rezultatele sunt îmbunătățite în medie cu 40%, atunci când este eliminată restricția de dimensiune. Aceasta deoarece sunt explorate domenii mai largi ale spațiului soluțiilor. În cazul impunerii restricțiilor de dimensiune, îmbunătățirea medie față de algoritmul Fiduccia-Mattheyses este de 28% în privința capacității tăieturii și de 20% în privința raportului de tăietură.

3.4.6 Partiționarea cu performanțe stabile

Performanțele algoritmului Kernighan-Lin s-au dovedit a fi foarte dependente de alegerea partiției inițiale, iar rezultatele finale variază în mod semnificativ ca o consecință a diferitelor partiții de început [50]. Pentru a se evita blocarea în minime locale, este necesar un număr mare de rulări ale algoritmului asupra unor partiții inițiale generate aleator, proces care necesită un timp ridicat. În plus, probabilitatea de a găsi soluția optimă într-o singură încercare scade exponențial pe măsură ce dimensiunea circuitului crește.

Kernighan și Lin au sugerat faptul că o altă rulare a algoritmului de partiționare poate îmbunătăți rezultatele generate de prima încercare. Presupunem, de exemplu, că se obține rezultatul unei partiționări (A, B) pornind de la o anumită partiție inițială. Dacă se împarte A în A_1 și A_2 , iar B în B_1 și B_2 , se poate rula din nou algoritmul Kernighan-Lin fie asupra $(A_1 \cup B_1, A_2 \cup B_2)$, fie asupra $(A_1 \cup B_2, A_2 \cup B_1)$. Dacă se obține o partiție mai bună, procedura poate fi repetată. Totuși, îmbunătățirea obținută din rezultatul final precedent necesită mai mult timp, complexitatea fiind aceeași cu cea a problemei originale. În plus, trebuie să se indice o anumită dimensiune a subsetului înaintea generării partiției inițiale. Acest proces nu avantajează identificarea grupelor naturale din circuit, deoarece este imposibil să se determine dimensiunea grupelor înaintea partiționării.

Pe baza acestor observații, Cheng și Wei [50] ajung la concluzia că o tehnică de grupare de sus în jos este esențială pentru o partiționare eficientă. Pentru a reduce dimensiunea circuitelor, se utilizează o tehnică de partiționare recursivă de sus în jos, și se divide întregul circuit în grupuri mici, puternic conectate. Astfel, grupurile generate la fiecare partiționare se reduc ca dimensiune. Ultimul pas constă în rearanjarea grupurilor în două subseturi care respectă restricția de dimensiune. Deoarece numărul grupurilor este relativ mic comparativ cu numărul modulelor circuitului, se pot efectua numeroase încercări ale operației de rearanjare. De asemenea, există o probabilitate ridicată de a se obține o soluție apropiată de cea optimă, deoarece numărul grupurilor

generate este mic. Algoritmul de partiționare se bazează pe tăietura proporțională [175].

Circuitul este divizat mai întâi în grupuri mici, prin execuția recursivă a algoritmului de tăietură proporțională. Fiecare grup va conține un număr diferit de module de dimensiuni diferite. Aceste grupuri sunt rearanjate apoi în două subseturi, respectându-se restricțiile de dimensiune. Scopul principal al acestei etape este de a se minimiza ponderea tăieturii între cele două subseturi. Se aplică apoi algoritmul Fiduccia-Mattheyses circuitului contractat, în mod repetat, pentru a se obține rezultate bune. În final, se execută din nou algoritmul Fiduccia-Mattheyses asupra circuitului original expandat.

Un circuit având conexiuni multipin poate fi definit cu ajutorul un model de hipergraf. Fie $N = (V, E)$ reprezentând circuitul având m module și n conexiuni, unde $V = \{V_1, V_2, \dots, V_m\}$ și $E = \{e_1, e_2, \dots, e_n\}$. Fiecare muchie, care corespunde unei conexiuni multipin, este un subset al lui V , deci $e_i \subseteq V$, $|e_i| \geq 2$, $1 \leq i \leq n$. Se aplică în mod recursiv algoritmul de tăietură proporțională circuitului N și se divide V într-un număr de grupuri mici, m' . Fie Ψ un set pentru colecția grupurilor generate, $\Psi = \{V_i | 1 \leq i \leq m'\}$. Se construiește apoi un circuit contractat $H = (V', E')$ după cum urmează. În primul rând, fiecare element din Ψ va fi un nod în circuitul contractat, deci $V' = \{i | V_i \in \Psi\}$. Apoi, pentru fiecare muchie e_j din E se construiește o nouă muchie e_j' . Muchia e_j' conectează nodul i din V' dacă e_j conectează oricare module din V_i , deci $e_j' = \{i | \text{există } v_k \in V_i, \text{ astfel încât } v_k \in e_j\}$. În final, $E' = \{e_j' | |e_j'| \geq 2\}$.

Fiind dat un circuit $N = (V, E)$, un întreg g indicând numărul grupurilor așteptate, un întreg nr_rep indicând numărul de repetări, iar $dim1$ și $dim2$ restricțiile de dimensiune ale celor două subseturi rezultante, algoritmul de partiționare cu performanțe stabile poate fi descris astfel:

1. Se inițializează $\Psi = V$ și se calculează dimensiunea totală a circuitului $dimt$.
2. Fie V^* un subset din Ψ astfel încât $|V^*| = \max_{V_i \in \Psi} |V_i|$. Cât timp $|V^*| > dimt/g$, repetă pasul 3.
3. Se setează $\Psi = \Psi - \{V^*\}$. Se aplică algoritmul de tăietură proporțională [175] subsetului V^* pentru a obține o tăietură (A, A') unde $V^* = A \cup A'$. Se setează $\Psi = \Psi \cup \{A, A'\}$.
4. Se construiește un circuit contractat $H = (V', E')$.
5. Se aplică algoritmul Fiduccia-Mattheyses de nr_rep ori circuitului H cu restricțiile de dimensiune $dim1, dim2$.
6. Se utilizează rezultatul cel mai bun de la pasul 5 pentru circuitul N . Se aplică algoritmul Fiduccia-Mattheyses o singură dată circuitului N cu restricțiile de dimensiune $dim1, dim2$.

Fiind dată o valoare g , fie $f(g)$ numărul de grupuri generate după execuția partiționării recursive în pașii 2 și 3. Deoarece tăietura proporțională necesită $O(p)$ operații [175], unde p este numărul total de pini, iterațiile din pașii 2 și 3 necesită cel mult $O(f(g) \times p)$ operații. Complexitatea pasului 4 este $O(p)$, iar complexitatea pașilor 5 și 6 este $O(nr_rep \times p)$. Astfel, complexitatea întregului algoritm este limitată la $O((f(g) + nr_rep) \times p)$.

În experimentele efectuate Cheng și Wei [50], valoarea medie a ponderii tăieturii este ridicată atunci când g are valoare mică, $g < 25$. Pentru valori peste 100, numărul de subseturi din Ψ se apropie de numărul total de module ale circuitului, iar operațiile se comportă similar cu algoritmul Fiduccia-Mattheyses. Rezultatele cele mai bune s-au obținut pentru g cuprins între 25 și 100, pentru alte experimente fiind aleasă valoarea $g = 50$. Cu algoritmul de partiționare cu performanțe stabile s-a obținut o îm-

bunătățire de 25% față de cele mai bune rezultate și de 48% față de media rezultatelor obținute cu algoritmul Fiduccia-Mattheyses [50].

3.4.7 Partiționarea prin metode spectrale

O clasă importantă de tehnici de partiționare este reprezentată de metodele "spectrale", care utilizează valori proprii și vectori proprii ale matricilor obținute din graful circuitului. Un circuit poate fi reprezentat ca un graf nedirecționat $G = (V, E)$ cu $|V| = n$ vârfuri v_1, \dots, v_n . G se poate reprezenta printr-o *matrice de adiacență* de $n \times n$ elemente $A = A(G)$, unde $A_{ij} = 1$ dacă $(v_i, v_j) \in E$ și $A_{ij} = 0$ în caz contrar. Dacă G are muchii ponderate, A_{ij} este egal cu ponderea muchiei $(v_i, v_j) \in E$, și prin convenție $A_{ij} = 0$ pentru orice $i = 1, \dots, n$. Dacă se notează cu $d(v_i)$ gradul vârfului v_i (suma ponderilor tuturor muchiilor incidente lui v_i), se obține *matricea de grad*, notată cu D , care este o matrice diagonală definită prin $D_{ii} = d(v_i)$. Uneori, se utilizează d_i pentru a nota $d(v_i)$. Valorile proprii și vectorii proprii ale unor asemenea matrici sunt studiate de un subdomeniu al teoriei grafurilor care se ocupă de spectrele grafurilor.

Studii teoretice efectuate de Barnes, Donath și Hoffman au stabilit relații între proprietățile spectrale și proprietățile de partiționare ale grafurilor [86]. Au fost utilizate metode bazate pe vectori proprii și valori proprii pentru plasarea modulelor în sisteme CAD, și pentru bisecționarea cu lățime minimă. În contextul amplasării circuitelor, aceste studii formulează problema de partiționare ca asignarea sau plasarea modulelor în grupuri de dimensiune limitată. Problema este transformată apoi într-o optimizare quadratică, și o formulare a unui Lagrangian conduce apoi la calculul unor vectori proprii.

Hagen și Kahng au arătat în [86] legătura teoretică existentă între spectrele grafurilor și tăieturile proporționale optime. În teoria dezvoltată se utilizează vectori proprii ale matricii $Q = D - A$, numită Laplacian al lui G , unde D și A sunt definite mai sus, matrice care a fost utilizată și de către Hall [87]. Boppana, Donath și Hoffman, ca și alți autori, utilizează matrici diferite derivate din graful circuitului, dar se bazează pe proprietăți matematice similare pentru a elabora formulări bazate pe valori proprii și a defini relația existentă cu partiționarea.

După cum a arătat Hall [87], vectorii matricii $Q = D - A$ soluționează problema de *plasare quadratică* uni-dimensională pentru determinarea vectorului $x = (x_1, x_2, \dots, x_n)$ care minimizează

$$z = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2 A_{ij} \quad (3.21)$$

cu restricția $|x| = (x^T x)^{1/2} = 1$.

Se poate arăta că $z = x^T Q x$, astfel că pentru a minimiza z se poate forma un Lagrangian

$$L = x^T Q x - \lambda(x^T x - 1) \quad (3.22)$$

Dacă se consideră prima derivată parțială a lui L față de x și se egalează cu zero rezultă

$$2Qx - 2\lambda x = 0 \quad (3.23)$$

care se poate rescrie ca

$$(Q - \lambda I) x = 0 \quad (3.24)$$

unde I este matricea de identitate. Aceasta este o formulare bazată pe valori proprii pentru λ , iar vectorii proprii ai lui Q sunt singurele soluții pentru x care nu sunt banale. Valoarea proprie minimă 0 conduce la soluția neinteresantă $x = (1/\sqrt{n}, 1/\sqrt{n}, \dots, 1/\sqrt{n})$.

..., $1/\sqrt{n}$), și de aceea se utilizează vectorul propriu corespunzător celei de-a doua valori proprii.

Hagen și Kahng [86] au arătat următoarele proprietăți de bază ale matricii Q :

- Q este simetrică și non-negativă, deci (i) $x^T Q x = \sum_{i,j} Q_{ij} x_i x_j \geq 0 \forall x$, și (ii) toate valorile proprii ale lui Q sunt ≥ 0 .
- Valoarea proprie minimă a lui Q este 0, cu vectorul propriu $\mathbf{1} = (1, 1, \dots, 1)$.
- Produsul intern $x^T Q x$ corespunde "lungimii pătrate", deci

$$x^T Q x = x^T D x - x^T A x = \sum_i d_i x_i^2 - \sum_{i,j} A_{ij} x_i x_j = \sum_i d_i x_i^2 - 2 \sum_{(i,j) \in E} x_i x_j$$

care se poate scrie ca pătratul complet

$$x^T Q x = \sum_{(i,j) \in E} (x_i - x_j)^2 \quad (3.25)$$

- În final, principiul Minimax Courant-Fischer [86] implică

$$\lambda = \min_{x \perp \mathbf{1}, x \neq \mathbf{0}} \frac{x^T Q x}{|x|^2} \quad (3.26)$$

unde λ este a doua valoare proprie cea mai mică a lui Q .

Proprietățile c) și d) stabilesc o nouă relație între costul tăieturii proporționale optime și a doua valoare proprie λ a matricii $Q = D - A$. Aceasta este formulată în următoarea teoremă [86].

Teorema 3.4.7.1. Fiind dat un graf $G = (V, E)$ cu matricea de adiacență A , matricea diagonală de grad D , și $|V| = n$, a doua valoare proprie cea mai mică λ a lui $Q = D - A$ indică o limită inferioară a costului c al partiției tăieturii proporționale optime, cu $c \geq (\lambda/n)$.

Rezultatele acestei teoreme sugerează următoarea metodă de partiționare: se calculează $\lambda(Q)$ și vectorul propriu corespunzător x , și apoi se utilizează x pentru a construi o euristică pentru tăietura proporțională. Dacă circuitul este specificat ca un hipergraf $H = (V, E)$, atunci acesta trebuie transformat mai întâi într-un graf $G = (V, E)$.

Pentru transformarea hipermuchiiilor din modelul circuitului în muchii ale grafului G se consideră că fiecare conexiune cu k pini contribuie cu un subgraf complet conținând cele k module ale sale, ponderea fiecărei muchii fiind egală cu $1/(k-1)$. Deci, matricea de adiacență A este construită astfel: Pentru fiecare pereche de module v_i și v_j cu $p \geq 1$ conexiuni în comun, fie $|s_1|, |s_2|, \dots, |s_p|$ numărul modulelor din conexiunile comune s_1, s_2, \dots, s_p . Atunci

$$A_{ij} = \sum_{l=1}^p \frac{1}{|s_l| - 1} \quad (3.27)$$

Se pot considera și diferite metode de rarificare a matricii Q , de exemplu ignorarea conexiunilor mai puțin importante (non-critice), sau aproximarea cu 0 a elementelor cu valoare mică ale matricii. Aceste metode sunt importante deoarece cei mai mulți algoritmi numerici vor avea un timp de execuție mai redus în cazul intrărilor reprezentate prin matrici rare.

Deoarece trebuie calculat un singur vector propriu al unei matrici simetrice, complexitatea acestui calcul este relativ redusă. În plus, matricile de adiacență ale cir-

cuitelor tind să fie rare datorită organizării ierarhice a circuitului și a restricțiilor tehnologice. Aceasta permite aplicarea tehnicilor numerice pentru matricile rare, în particular a metodei Lanczos.

Fiind dată o matrice Q de $n \times n$ elemente, algoritmul Lanczos calculează în mod iterativ o matrice simetrică tridiagonală T a cărei valori proprii vor fi foarte apropiate de valorile proprii ale lui Q . Dacă numărul de valori proprii care trebuie calculate este redus, numărul de iterații necesare pentru obținerea matricii T va fi de obicei mult mai mic decât n . Deoarece T este tridiagonală și simetrică, se poate calcula rapid o valoare proprie λ a matricii T , care se poate utiliza pentru calculul vectorului propriu x corespunzător matricii Q .

Pornind de la al doilea vector propriu x , se pot utiliza următoarele euristici pentru construirea partiției pe baza tăieturii proporționale [86]:

- a) Partiționarea modulelor pe baza $\text{sgn}(x)$, deci $U = \{\text{modul } i: x_i \geq 0\}$ și $W = \{\text{modul } i: x_i < 0\}$.
- b) Partiționarea modulelor în jurul valorii mediane x_i , depunând prima jumătate în U și a doua jumătate în W .
- c) Utilizarea relației euristice între x și o plasare quadratică uni-dimensională, conform căreia un interval în lista sortată a valorilor x_i indică o partiție naturală.
- d) Sortarea x_i pentru a obține o ordonare liniară a modulelor, iar apoi determinarea indexului de divizare r care produce tăietura proporțională cea mai bună.

În cazul d), cele n componente x_i ale vectorului propriu sunt sortate, rezultând o ordonare $v = v_1, \dots, v_n$ a modulelor. Este determinat apoi indexul de divizare r , $1 \leq r \leq n-1$, care produce cel mai bun cost al tăieturii proporționale atunci când modulele cu indexul $> r$ sunt plasate în U , iar cele cu indexul $\leq r$ sunt plasate în W .

Algoritmul de partiționare care utilizează euristica d) pentru construirea partiției este prezentat în Figura 3.9.

Algorithm EIG1;
begin $H = (V, E')$ este hipergraful circuitului;
Pas 1. Se transformă fiecare hipermuchie cu k pini din H într-un subgraf complet din $G = (V, E)$ cu ponderea uniformă a muchiiilor $1/k - 1$;
Pas 2. Se calculează $A =$ matricea de adiacență și $D =$ matricea de grad a grafului G ;
Pas 3. Se calculează a doua valoare proprie cea mai mică a matricii $Q = D - A$ prin algoritmul Lanczos;
Pas 4. Se calculează vectorul propriu asociat v ;
Pas 5. Se sortează componentele lui v și se determină indexul de divizare care produce tăietura proporțională cea mai bună;
Pas 6. Se returnează partiția cea mai bună găsită
end.

Figura 3.9. Algoritmul de partiționare pe baza vectorilor proprii.

Un număr de autori au arătat faptul că găsirea grupurilor naturale din cadrul circuitelor este utilă pentru mai multe aplicații, de exemplu: a) partiționarea cu câi multiple, în special atunci când dimensiunile partițiilor nu sunt cunoscute dinainte; b) amplasarea constructivă a modulelor; c) situațiile în care dimensiunea circuitului este foarte mare și trebuie utilizată gruparea pentru a reduce dimensiunea intrării asupra căreia se aplică partiționarea. Aceste grupuri pot fi găsite în mod eficient prin

utilizarea metodei spectrale, deoarece al doilea vector propriu x conține atât informații de partiționare, cât și de grupare. Hagen și Kahng au arătat că o interpretare directă a celui de-al doilea vector propriu sortat poate identifica imediat grupurile naturale din cadrul grafului. Rezultatele obținute sunt foarte bune mai ales pentru circuite de dimensiuni mari.

Deoarece partiționarea pe baza vectorilor proprii ignoră informațiile despre suprafața modulelor, această metodă este adecvată pentru circuite bazate pe celule standard sau rețele de porți [86]. Faptul că metoda spectrală ignoră ponderile modulelor nu constituie o dificultate pentru numeroase aplicații de partiționare utilizate în proiectarea asistată, de exemplu pentru test sau simulare hardware, unde intrarea este reprezentată de hipergraful circuitului cu ponderi uniforme ale nodurilor.

În urma experimentelor efectuate în [86], prin metoda spectrală s-a obținut o îmbunătățire medie de 9% a raportului de tăietură față de rezultatul obținut de Wei și Cheng [175] prin metoda tăieturii proporționale, implementată prin programul RCut1.0. Timpul de calcul este competitiv cu cel al programului RCut1.0. Chiar și partițiile inițiale generate prin metoda spectrală au calitate mai bună decât partițiile obținute în urma îmbunătățirilor iterative.

3.4.8 Partiționarea pe baza rețelelor de flux

Teorema fluxului maxim și tăieturii minime (Ford și Fulkerson) pentru rețele este o importantă tehnică combinatorică de optimizare. Aceasta are numeroase aplicații în proiectarea circuitelor VLSI, ca de exemplu plasarea liniară sau maparea tehnologică pentru circuitele FPGA. Tehnica fluxului maxim și tăieturii minime este o metodă naturală de aflare a tăieturii minime într-un graf. Totuși, ea nu a fost utilizată pe scară largă pentru partiționarea circuitelor din următoarele motive:

- 1) Cele două componente obținute pot fi dezechilibrate.
- 2) Deși se poate obține o tăietură echilibrată prin aplicarea repetată a tăieturii minime componenteii celei mai mari, această metodă poate necesita n operații de calcul a fluxului maxim, unde n este dimensiunea rețelei.
- 3) Tehnica tradițională de flux în rețele operează asupra grafurilor, dar hipergrafurile reprezintă modele de acuratețe mai mare pentru listele de conexiuni ale circuitelor decât grafurile.

Yang și Wong [180] au propus o metodă pentru modelarea exactă a unei liste de conexiuni (sau, în mod echivalent, a unui hipergraf) printr-o rețea de flux, și o euristică de bipartiționare echilibrată bazată pe utilizarea repetată a tehnicii fluxului maxim și tăieturii minime. Aceștia utilizează o noțiune de *bipartiție r -echilibrată*, care este o bipartiție astfel încât o componentă are o pondere care este o fracțiune r a ponderii totale W . În cazul special când $r = \frac{1}{2}$, o bipartiție r -echilibrată este o bipartiție echilibrată. Deoarece în practică nu este necesară impunerea strictă a criteriului de r -echilibrare, se poate introduce un factor de deviere ϵ pentru a permite devierea ponderii unei componente de la $(1 - \epsilon) rW$ la $(1 + \epsilon) rW$.

O rețea de flux $G = (V, E)$ este un graf orientat în care fiecare muchie $e \in E$ are o *capacitate* $c(e) \geq 0$. Sunt specificate două noduri s și t din V : nodul s este numit *sursă*, iar nodul t este numit *destinație* (Figura 3.10). Un *flux s - t* (sau *flux*) din G este o funcție cu valori reale $f: E \rightarrow R$ astfel încât

- 1) pentru toate muchiile $e \in E$, $0 \leq f(e) \leq c(e)$, și
- 2) pentru toate nodurile $u \in V \setminus \{s, t\}$, suma fluxului de intrare în u este egală cu suma fluxului de ieșire din u .

O muchie e din E este *saturată* dacă $f(e) = c(e)$. Valoarea $|f|$ a unui flux f este definită ca suma fluxului de ieșire din s , care este egală cu suma fluxului de intrare în t . Un *flux maxim* din G este un flux cu valoare maximă din s în t .




Figura 3.10. Un exemplu de rețea de flux G și tăietura corespunzătoare de capacitate minimă.

O *tăietură s-t* (sau *tăietură*) (X, X') a unei rețele de flux $G = (V, E)$ este o bi-partiție a lui V în X și X' astfel încât $s \in X$ și $t \in X'$. O muchie cu nodul de început în X și nodul de sfârșit în X' este numită *muchie directă*. O muchie cu nodul de sfârșit în X și nodul de început în X' este numită *muchie inversă*. *Capacitatea tăieturii* (X, X') , notată prin $cap(X, X')$, este suma capacităților numai pe muchiile directe din X în X' . O *cale de augmentare* din u în v este o cale simplă din u în v din graful nedirecționat obținut din rețea prin ignorarea direcției muchiilor, care se poate utiliza pentru a crea un flux suplimentar din u în v .

Teorema fluxului maxim și tăieturii minime poate fi enunțată astfel [180]:

Teorema 3.4.8.1. Fiind dat un flux maxim f din G , fie $X = \{v \in V : \exists \text{ o cale de augmentare în } G \text{ din } s \text{ în } v\}$, și fie $X' = V \setminus X$. Atunci (X, X') este o tăietură de capacitate minimă (care este egală cu $|f|$), și f saturează toate muchiile directe din X în X' .

Figura 3.10 exemplifică un flux maxim în G și tăietura corespunzătoare de capacitate minimă. Eticheta x/y a unei muchii indică faptul că fluxul și capacitatea muchiei sunt x , respectiv y . Muchiile îngroșate sunt muchii directe ale tăieturii (X, X') .

În continuare se descrie modelarea unei conexiuni într-o rețea de flux.

Lista de conexiuni a unui circuit secvențial se poate reprezenta ca un *digraf* (care poate conține cicluri direcționate) $N = (V, E)$, unde V este un set de noduri reprezentând porți combinatoriale și registre, iar E este un set de muchii reprezentând interconexiunile dintre porți și registre. Fiecare nod v din V are o pondere asociată $w(v) \in \mathbb{R}^+$. Ponderea totală a unui subset $U \subseteq V$ este notată prin $w(U)$. Fie $W = w(V)$ ponderea totală a circuitului N .




Figura 3.11. Un digraf N reprezentând un circuit secvențial și tăieturile conexiunilor acestuia.

O conexiune $n = (v, v_1, \dots, v_l)$ din N este un set de muchii de ieșire din nodul v . De exemplu, în Figura 3.11 conexiunea a constă din două muchii (r_1, g_1) și (r_1, g_2) . Fiind date două noduri s și t din N , o tăietură s - t (sau tăietură) (X, X') din N este o bipartiție a nodurilor din V astfel încât $s \in X$ și $t \in X'$. Conexiunile tăiate ale tăieturii, notate cu $net(X, X')$, sunt reprezentate de setul de conexiuni din N care sunt incidente atât nodurilor din X , cât și celor din X' . În Figura 3.11, dacă se alege $s = g_1$ și $t = g_3$, atunci setul de conexiuni tăiate $net(Y, Y')$ corespunzătoare tăieturii (Y, Y') constă din conexiunile c, a, b, e , unde conexiunile c, a, b conectează noduri din Y cu cele din Y' , iar conexiunea e conectează un nod din Y' cu unul din Y . O tăietură (X, X') este o tăietură minimă a conexiunilor dacă $|net(X, X')|$, deci numărul de conexiuni din $net(X, X')$, este minim dintre toate tăieturile lui N . În Figura 3.11, $net(X, X') = \{b, e\}$, $net(Y, Y') = \{c, a, b, e\}$, iar (X, X') este o tăietură minimă a conexiunilor.

Problema găsirii unei tăieturi minime a conexiunilor în $N = (V, E)$ se poate reduce la problema găsirii unei tăieturi de capacitate minimă, care se poate rezolva prin teorema fluxului maxim și tăieturii minime. Dacă toate muchiile tăiate au o capacitate unitară, problema este echivalentă cu găsierea unei tăieturi cu numărul minim de muchii directe din X în X' .

Construirea unei rețele de flux $N' = (V', E')$ din $N = (V, E)$ se poate realiza prin următoarea procedură [180] (Figura 3.12):




Figura 3.12. (a) O conexiune n în circuitul N . (b) Nodurile și muchiile conexiunii n din N' .

1. V' va conține inițial toate nodurile din V .
2. Pentru fiecare conexiune $n = (v, v_1, \dots, v_l)$ din N , se adaugă două noduri n_1 și n_2 în V' și o muchie punte (n_1, n_2) în E' .
3. Pentru fiecare nod $u \in \{v, v_1, \dots, v_l\}$ incident conexiunii n , se adaugă două muchii (u, n_1) și (n_2, u) în E' .
4. Fie s sursa lui N' și t destinația lui N' .
5. Se asignează capacități unitare tuturor muchiilor punte și capacități infinite tuturor celorlalte muchii din E' .
6. Pentru un nod $v \in V'$ corespunzător unui nod din V , $w(v)$ este ponderea lui v din N . Pentru un nod $u \in V'$ divizat dintr-o conexiune, $w(u) = 0$.

Lema 3.4.8.2 arată că dimensiunea rețelei de flux N' este mai mare doar cu un factor constant față de dimensiunea digrafului N .

Lema 3.4.8.2. Fie $N' = (V', E')$ rețeaua de flux construită dintr-un digraf $N = (V, E)$ utilizând procedura descrisă anterior. Atunci $|V'| \leq 3|V|$ și $|E'| \leq 2|E| + 3|V|$.

Procedura de construire a unei rețele de flux se poate aplica și atunci când circuitul N este reprezentat printr-un hipergraf.

Ihler, Wagner și Wager au arătat în [97] că modelarea hipergrafurilor prin grafuri (cu ponderi pozitive) cu aceleași proprietăți de tăietură minimă nu este posibilă. Metoda descrisă mai sus modelează un hipergraf numai pentru algoritmi de partiționare bazată pe rețele de flux. Diferențele dintre modelul utilizat în [97] și modelul de sus sunt următoarele:

- 1) Ponderea unei tăieturi în [97] este calculată ca suma tuturor muchiilor tăiate cu ponderi fixe, în timp ce în procedura descrisă ponderea unei tăieturi este calculată ca suma capacităților muchiilor directe.
- 2) În [97] se încearcă modelarea hipergrafurilor pentru un domeniu larg de algoritmi de partiționare elaborată numai pentru grafuri obișnuite, în timp ce în procedura de sus se modelează un hipergraf numai pentru algoritmi bazată pe rețele de flux.

În Teorema 3.4.8.3 și Corolarul 3.4.8.4 [180] se arată că problema determinării unei tăieturi minime a conexiunilor din N se poate reduce la problema determinării unei tăieturi cu capacitate minimă din N' .

Teorema 3.4.8.3. N are o tăietură cu dimensiunea tăieturii conexiunilor de cel mult C dacă și numai dacă N' are o tăietură de capacitate cel mult C .

Corolarul 3.4.8.4. Fie (Y, Y') o tăietură de capacitate minimă C din N' , și fie (X, X') tăietura din N construită astfel: Se elimină toate conexiunile din N corespunzătoare muchiilor directe de la Y la Y' . N va fi divizat atunci în mai multe componente disjuncte, iar s și t vor fi în componente diferite. Se alege X ca fiind componenta conținând s , iar X' reuniunea celorlalte componente. Atunci (X, X') este o tăietură minimă a conexiunilor din N , iar $|net(X, X')| = C$.

Ca rezultat al corespondenței între hipergrafuri și rețelele de flux se poate găsi o tăietură minimă a conexiunilor într-un circuit, utilizând următorul algoritm.

1. Se construiește rețeaua de flux $N' = (V', E')$ pentru N după procedura descrisă anterior.
2. Se determină un flux maxim în N' de la s la t .
3. Se determină o tăietură (Y, Y') de capacitate minimă în N' , în modul descris în teorema de fluxului maxim și tăieturii minime (Teorema 3.4.8.1).
4. Se determină o tăietură minimă a conexiunilor (X, X') în N , după modul descris la Corolarul 3.4.8.4.

Bipartiția cu tăietura minimă poate fi dezechilibrată. Calcularea fluxului maxim definește un set de tăieturi minime cu aceeași dimensiune a tăieturii, dar cu ponderi diferite în cele două partiții. Se pune problema găsirii unei tăieturi minime care este cea mai *r-echilibrată* dintre toate tăieturile definite de un flux maxim, deci găsirea dintre toate tăieturile minime posibile (X, X') definite de un flux maxim a tăieturii minime astfel încât $|w(X) - r w(V)|$ să fie cât mai apropiat de 0. Această problemă este NP-completă [180].

Prin aplicarea repetată a tehnicii fluxului maxim și tăieturii minime pentru divizarea partiției celei mai mari se poate obține în final o bipartiție echilibrată. Această metodă nu este însă una viabilă pentru partiționarea circuitelor datorită complexității sale ridicate (sunt posibile $|V|$ calculări ale fluxului maxim). Yang și Wong [180] au elaborat o euristică pentru determinarea unei bipartiții *r-echilibrate* care minimizează numărul de conexiuni tăiate, numită bipartiționare cu echilibrarea fluxului.

Fiind dat un circuit $N = (V, E)$, algoritmul de bipartiționare cu echilibrarea fluxului selectează în mod aleator o pereche de noduri s și t din N , și apoi încearcă găsirea unei bipartiții *r-echilibrate* care separă s și t , și care minimizează numărul de conexiuni

tăiate. Fie W ponderea totală a circuitului N . Deoarece nu este necesară impunerea strictă a criteriului de r -echilibrare, se permite devierea ponderii unei componente de la $(1 - \epsilon) rW$ la $(1 + \epsilon) rW$. Fiind dat un subcircuit X al lui N , fie $w(X)$ ponderea totală a nodurilor din X .

Algoritmul este prezentat în Figura 3.13.

Pasul 1 poate fi implementat prin algoritmul pentru determinarea tăieturii minime a conexiunilor. În pasul 4.2 este necesară comasarea în s a unui nod $v \in X'$ incident pe o conexiune tăiată, deoarece în caz contrar în următoarea iterație în pasul 1 se va alege același set de conexiuni din C ca și tăietură minimă a conexiunilor. Prin comasarea v în s , algoritmul poate explora o altă tăietură a conexiunilor cu un subcircuit X mai mare în următoarea iterație. În mod similar se procedează și în pasul 5.2.

Un dezavantaj al euristicii fluxului maxim este că timpul de execuție este ridicat, datorită execuției iterative a algoritmului pentru determinarea tăieturii minime a conexiunilor. O implementare mai eficientă se poate realiza pe baza observației că nu este necesar să se execute calculul pentru fluxul maxim de la fluxul 0 în fiecare iterație. Valoarea fluxului din rețea poate fi reținută, și în fiecare iterație se poate găsi un flux suplimentar pentru a satura muchiile punte.

```

Algorithm FBB;
begin
Pas 1. Se alege în mod aleator o pereche de noduri  $s$  și  $t$  din  $N$ ;
Pas 2. Se determină o tăietură minimă a conexiunilor  $C$  din  $N$ ;
      Fie  $X$  subcircuitul accesibil din  $s$  prin căi de augmentare în rețeaua
      de flux, și  $X'$  restul circuitului;
Pas 3. if  $(1 - \epsilon) rW \leq w(X) \leq (1 + \epsilon) rW$  then
      STOP;
      Se returnează  $C$ 
      endif;
Pas 4. if  $w(X) < (1 - \epsilon) rW$  then
      4.1 Se comasează toate nodurile din  $X$  în  $s$ ;
      4.2 Se comasează în  $s$  un nod  $v \in X'$  adiacent cu  $C$ ;
      4.3 goto Pas 1
      endif;
Pas 5. if  $w(X) > (1 + \epsilon) rW$  then
      5.1 Se comasează toate nodurile din  $X'$  în  $t$ ;
      5.2 Se comasează în  $t$  un nod  $v \in X$  adiacent cu  $C$ ;
      5.3 goto Pas 1
      endif
end.

```

Figura 3.13. Algoritmul de bipartiționare cu echilibrarea fluxului.

În urma experimentelor efectuate în [180] algoritmul de bipartiționare cu echilibrarea fluxului (*FBB*) a fost comparat cu algoritmul Krishnamurthy [105] și cu o altă euristică de tip Kernighan-Lin. Rezultatele obținute arată că prin algoritmul *FBB* se obține o bipartiție la care numărul de conexiuni tăiate este mai redus în medie cu 24%, respectiv cu 19% față de cea obținută prin euristiciile amintite. Comparativ cu algoritmul *EIG1* bazat pe metode spectrale, descris în secțiunea 3.4.7, rezultatele obținute prin algoritmul *FBB* sunt mai bune în medie cu 11%.

S-a observat că în cazul în care timpul de execuție al algoritmului *FBB* este mai mare decât cel mediu, calitatea soluțiilor generate este foarte redusă [180]. Aceasta se poate explica prin faptul că dimensiunea tăieturii conexiunilor nu este descrescătoare cu numărul de iterații. Această proprietate a algoritmului *FBB* este în contrast cu euristica Kernighan-Lin și cea de călire simulată, la care un timp de execuție mai mare are

ca efect generarea unei soluții mai bune. Această proprietate a algoritmului *FBB* indică un mod de îmbunătățire a eficienței acesteia. Se poate alege o limită superioară a timpului de execuție a algoritmului, oprind execuția algoritmului atunci când timpul de execuție depășește această limită, relansând algoritmul cu o nouă pereche de noduri s și t .

Algoritmul *FBB* are o comportare predictibilă în privința dimensiunilor celor două partiții. Timpul de execuție și dimensiunea tăieturii sunt funcții descrescătoare cu factorul de deviere ε . Alegerea perechii de noduri s și t ca și configurație inițială are o influență mai mică asupra soluției decât alegerea unei bipartiții inițiale.

3.4.9 Multipartiționarea

Multipartiționarea sau partiționarea cu căi multiple este o extensie importantă a bipartiționării deoarece asigură un model natural și de acuratețe mai mare pentru numeroase aplicații de partiționare. Acest tip de partiționare a fost abordat prin diferite metode: prin călire simulată [105], prin utilizarea vectorilor proprii ale matricilor provenite din lista de conexiuni a circuitului [39], [86], [87], sau prin migrarea grupurilor [105], [155]. Acestea din urmă se concentrează asupra evaluării mutărilor care determină îmbunătățirea maximă a partiției curente. Au fost propuse mai multe modele pentru evaluarea mutărilor: modelul câștigului cu nivele multiple, modelul probabilistic al conexiunilor intersectate, sau modelul clicii ponderate.

Yeh *et al.* [183] au propus un algoritm de partiționare cu îmbunătățire iterativă care utilizează un nou model pentru procesul de mutare. În plus, algoritmul poate utiliza diferite funcții obiectiv cu aplicații în proiectarea circuitelor VLSI.

Un sistem este reprezentat printr-un hipergraf $H(V, E)$, unde $V = \{v_i \mid i = 1, 2, \dots, n\}$ este setul nodurilor și $E = \{e_u \mid u = 1, 2, \dots, m\}$ este setul conexiunilor. Fiecare conexiune e_u este un subset al lui V cu cardinalitatea $|e_u| \geq 2$. Fiecare nod v_i are dimensiunea $s(v_i)$. $S(V) = \sum_{v \in V} s(V_i)$ reprezintă dimensiunea hipergrafului H . O partiționare cu k căi asignează nodurile lui V în k partiții, cu fiecare partiție b conținând un subset nevid V_b al lui V . Se definește *acoperire* a unei conexiuni e ca fiind 0 dacă e aparține unei singure partiții, și f dacă e conectează f partiții, cu $f \geq 2$.

Yeh *et al.* [183] au definit trei funcții obiectiv diferite.

Funcția obiectiv 1. Pentru circuitele integrate scopul este minimizarea numărului maxim de pini de I/E a fiecărei partiții (capsule). Fie numărul de pini de I/E ai partiției b notat cu $|\{e_u \mid \text{acoperire}(e_u) \geq 2, e_u \cap V_b \neq \emptyset\}|$. Funcția obiectiv se poate exprima astfel:

$$\Psi_{\max I/E} : \min \max_{b \in \{1..k\}} |\{e_u \mid \text{acoperire}(e_u) \geq 2, e_u \cap V_b \neq \emptyset\}| \quad (3.28)$$

Funcția obiectiv 2. În cazul proiectării arhitecturale la nivel de plăci, este de dorit să se minimizeze semnalele de interfață între diferite circuite. Se notează cu $|\{e_u \mid \text{acoperire}(e_u) \geq 2\}|$ numărul de conexiuni între circuite. Funcția obiectiv este de a minimiza acest număr.

$$\Psi_{\text{net}} : \min |\{e_u \mid \text{acoperire}(e_u) \geq 2\}| \quad (3.29)$$

Funcția obiectiv 3. În cazul rutării fizice, complexitatea poate fi redusă prin minimizarea numărului total de pini de I/E din toate partițiile. Funcția obiectiv este

$$\Psi_{\text{pin}} : \min \sum_{e_u \in E} \text{acoperire}(e_u) \quad (3.30)$$

Pentru fiecare funcție obiectiv există restricția

$$C_m \leq |V_b| \leq C_M \quad \text{pentru fiecare } b = 1, 2, \dots, k \quad (3.31)$$

unde C_m și C_M sunt două constante care indică limitele dimensiunii fiecărei partiții și $0 < C_m \leq C_M < S(V)$.

Euristica de partiționare cu căi multiple propusă de Yeh *et al.* se numește algoritmul *Primal-Dual* (PD). Algoritmul constă din trei faze: 1) partiționare recursivă prin tăietura proporțională pentru formarea grupurilor; 2) iterație *Primal-Dual* asupra sistemului grupat; 3) iterație *Primal-Dual* asupra sistemului original.

Algoritmul este prezentat în Figura 3.14.

```

Algorithm Primal-Dual ( $H, \text{lim\_buclare}, C_s$ );
begin
   $H_s = \text{Rcut-recursive}(H, C_s)$ ;
   $\text{contor} = 0$ ;
   $\text{partiție} = \text{NULL}$ ;
  while ( $\text{contor} < \text{lim\_buclare}$ )
     $P_s = \text{partiție inițială aleatoare a lui } H_s$ ;
     $P_{PD} = \text{Iterație-Primal-Dual}(P_s)$ ;
    if ( $\text{cost}(P_{PD}) < \text{cost}(\text{partiție})$ ) then
       $\text{partiție} = P_{PD}$ ;
    endif;
     $\text{contor} := \text{contor} + 1$ ;
  endwhile
  Se expandează  $H_s$  în  $H$ ;
   $P = \text{Iterație-Primal-Dual}(\text{partiție})$ ;
end.

```

Figura 3.14. Algoritmul Primal-Dual.

Faza 1: Partiționare recursivă prin tăietura proporțională

Algoritmii de bipartiționare de tip Kernighan-Lin [76], [105] au dezavantajul că adesea obțin un minim local atunci când dimensiunea circuitului crește. În cazul partiționării cu căi multiple, problema minimului local este mai critică, deoarece partițiile multiple cresc în mod semnificativ spațiul soluțiilor. Un mod obișnuit de a elimina acest dezavantaj este de a se grupa subcircuitele puternic conectate și apoi de a se condensa aceste grupuri în super-noduri înaintea execuției algoritmilor de tip Kernighan-Lin [105].

```

Procedure Rcut-recursive ( $H, C_s$ );
begin
   $\Psi = \{V\}$ ;
  do
    Se alege un subset  $V^* \in \Psi$  astfel încât  $S(V^*) = \max_{V_j \in \Psi} S(V_j)$ ;
     $\Psi = \Psi - \{V^*\}$ ;
    Se aplică algoritmul de partiționare prin tăietura proporțională
    [175] asupra  $V^*$  pentru a obține o tăietură  $(A, A')$ ,  $A \subseteq V^*$ ;
     $\Psi = \Psi \cup \{A, A'\}$ ;
  while ( $S(V^*) > C_s$ );
  return;
end

```

Figura 3.15. Partiționarea recursivă prin tăietura proporțională.

Pentru identificarea subcircuitelor puternic conectate se poate utiliza în mod recursiv bipartiționarea prin tăietura proporțională [175]. Această procedură este ilustrată în Figura 3.15.

Este importantă alegerea corectă a dimensiunii maxime a unui grup (C_s), care determină numărul de grupuri utilizate în faza următoare. Dacă C_s este prea mic, numărul de grupuri generate va fi mare, ceea ce poate micșora performanțele următoarei proceduri de partiționare. Dacă C_s este prea mare, se pot pierde informații de conectivitate de către procedura următoare. În [183] rezultatele cele mai bune s-au obținut pentru $C_s \approx 0.02 \times S(V)$.

Faza 2: Iterația Primal-Dual asupra sistemului grupat

Se va descrie mai întâi modelul propus de Yeh *et al.* [183] pentru selectarea nodurilor care vor fi mutate. În cazul algoritmilor de tip Kernighan-Lin, este mutat un singur nod la un moment dat dintr-o partiție în cealaltă. Pentru a se permite mutarea simultană a mai multor noduri conectate, este relaxată restricția de mutare a unui singur nod.

Fiind dată o conexiune e_u și o partiție b , se definește *setul critic* al conexiunii e_u față de partiția b ca

$$S_{ub} = \{v \mid v \in e_u \text{ și } v \in V_b\} \quad (3.32)$$

reprezentând toate nodurile din partiția b care sunt conectate prin conexiunea e_u . Se definește de asemenea *setul critic complementar* al conexiunii e_u față de partiția b ca

$$S_{u\bar{b}} = \{v \mid v \in e_u \text{ și } v \in \overline{V_b}\} \quad (3.33)$$

reprezentând toate nodurile conectate prin conexiunea e_u care nu sunt în partiția b . Definiția unei mutări poate fi reformulată folosind setul critic și setul critic complementar. În cazul funcției obiectiv Ψ_{maxIE} și Ψ_{pin} , o mutare asociată cu o conexiune e_u este definită prin plasarea setului critic S_{ub} într-o partiție diferită de V_b . În cazul funcției obiectiv Ψ_{net} , o mutare asociată cu o conexiune e_u este definită prin plasarea setului critic complementar $S_{u\bar{b}}$ în partiția V_b . Câștigul fiecărei mutări este calculat prin evaluarea modificării costului datorită mutării setului critic sau al celui critic complementar.

Acest model este numit "model de mutare bazat pe conexiuni", spre deosebire de cel utilizat în algoritmul Fiduccia-Mattheyses [76], care este numit "model de mutare bazat pe noduri".

Deși modelul de mutare bazat pe conexiuni contribuie în mai mare măsură la îmbunătățirea partiției curente, acest model este mai complex deoarece sunt implicate mai multe noduri în fiecare mutare. Cele două modele se pot utiliza în mod alternativ, fiecare aducând anumite îmbunătățiri față de dualul său. Procedura corespunzătoare este ilustrată în Figura 3.16, unde *Primal* se referă la utilizarea modelului de mutare bazat pe noduri, iar *Dual* se referă la utilizarea modelului de mutare bazat pe conexiuni.

Procedura *Primal* este similară cu algoritmul Fiduccia-Mattheyses cu următoarea adaptare pentru partiționarea cu căi multiple: Pentru fiecare partiție b , se păstrează o listă sortată de mutări care deplasează noduri din partiția b în fiecare din celelalte partiții. Această listă are aceeași structură cu cea din algoritmul Fiduccia-Mattheyses [76]. Câștigurile mutărilor sunt calculate conform cu funcția obiectiv Ψ_{maxIE} , Ψ_{net} sau Ψ_{pin} .

Procedura *Dual* este similară cu procedura *Primal* cu excepția faptului că toate operațiile se bazează pe conceptul seturilor critice și critice complementare. Principalele diferențe sunt următoarele: 1) În locul unui singur nod, se mută un set critic sau

set critic complementar, în funcție de tipul funcției obiectiv. 2) Operația de blocare se efectuează asupra unei conexiuni, deci dacă setul critic sau cel critic complementar al unei conexiuni a fost mutat, atunci toate mutările inițiate de această conexiune vor fi interzise în continuare. O mutare este *inițiată* de o conexiune e_u dacă această mutare este compusă din deplasarea setului critic sau al celui complementar asociat cu e_u .

```

Procedure Iterație-Primal-Dual (P);
begin
    P = Primal (P);
    faza_pd = 1;
    do
        if (faza_pd = 0) then
            P' = Primal (P);
        else if (faza_pd = 1) then
            P' = Dual (P);
        endif;
        if (cost (P') < cost (P)) then
            îmbunătățire = TRUE;
            P = P';
            faza_pd = 1 - faza_pd;
        else
            îmbunătățire = FALSE;
        endif;
    while (îmbunătățire = TRUE);
    return;
end

```

Figura 3.16. Procedura de iterație Primal-Dual.

Faza 3: Iterația Primal-Dual asupra sistemului original

În faza a doua a algoritmului *Primal-Dual* partiția curentă este optimizată prin gestiunea grupurilor ca noduri condensate. Este posibil ca mutarea acestor grupuri să nu permită optimizarea cu finețe a partiției. În faza a treia, se expandează grupurile și se execută o iterație suplimentară *Primal-Dual*. Prin execuția acestei faze se obține o îmbunătățire suplimentară a calității soluției.

Complexitatea algoritmului *Primal-Dual* se poate determina analizând complexitatea fiecărei faze. În faza de partiționare recursivă numărul de operații executate este de cel mult $O(nd)$, unde n este numărul de noduri, iar d este numărul maxim de conexiuni pe nod. Complexitatea procedurii *Primal* este similară cu cea a algoritmului Fiduccia-Mattheyses, care este $O(nd)$. Deoarece se construiesc partiții cu k căi, fiecare mutare a unui nod are $k-1$ direcții posibile. Deci, complexitatea procedurii *Primal* este de $k-1$ ori mai mare, care este $O(k \times nd)$. Dacă p este numărul maxim de pini pe conexiune, iar m este numărul total de conexiuni, complexitatea procedurii *Dual* este de $O(mkp^2d^2)$ [183].

3.4.10 Partiționarea prin metode probabilistice

Cele mai multe metode de partiționare prin îmbunătățire iterativă calculează câștigurile datorate mutării nodurilor pe baza informațiilor locale din lista de conexiuni care urmăresc îmbunătățirea imediată a tăieturii. Asemenea metode sunt algoritmul Kernighan-Lin sau variantele Schweikert-Kernighan și Fiduccia-Mattheyses ale acesteia. Krishnamurthy [105] a sugerat o metodă de calcul a câștigurilor pe baza unor informații mai globale, obținându-se partiții de calitate mai bună. Necesarul de memorie al acestui algoritm este foarte ridicat. Niciuna din aceste metode nu poate însă prevedea cu acuratețe starea viitoare a unei conexiuni.

Dutt și Deng [69], [70] au propus o metodă pe baze probabilistice pentru calculul câștigurilor, care poate determina implicațiile globale și viitoare ale mutării unui nod în orice etapă a procesului de partiționare. Fiecărui nod u i se asociază o probabilitate $p(M(u))$ (prescurtată ca $p(u)$) a evenimentului $M(u)$ ca u să fie mutat efectiv în celălalt subset în pasul curent al procesului de partiționare. Din această probabilitate se calculează câștigurile probabilistice (sau potențiale) $g(u)$ ale nodurilor, ceea ce furnizează o indicație corectă a beneficiului care se obține în urma mutării acestora în celălalt subset.

Problema care se pune este modul de obținere inițială a probabilităților $p(u)$ ale nodurilor. Aceste probabilități se calculează din câștigurile nodurilor - cu cât câștigul este mai mare, cu atât este mai mare probabilitatea unui nod de a fi mutat efectiv în celălalt subset. Această interdependență între probabilități și câștiguri este eliminată prin determinarea unei estimări ale probabilităților $p(u)$ prin una din două metode. În prima metodă, la începutul unei etape se asignează tuturor nodurilor aceeași probabilitate p_{init} , de exemplu 0.8. În cea de-a doua metodă, se calculează mai întâi câștigurile deterministice ale nodurilor, similar cu cele calculate prin metoda Fiduccia-Mattheyses. Din aceste câștiguri deterministice se determină probabilitățile inițiale ale nodurilor.

După ce s-au determinat probabilitățile inițiale, se calculează câștigurile probabilistice ale nodurilor. Din aceste câștiguri, se recalculază probabilitățile nodurilor, și din acestea se obțin câștiguri mai exacte ale nodurilor. Acest proces se repetă pentru un număr de iterații. După terminarea acestui proces inițial, nodurile cu câștigurile cele mai mari sunt mutate între cele două subseturi, ca și în cazul altor metode iterative. După fiecare mutare, se actualizează câștigurile și probabilitățile nodurilor. De asemenea, la fiecare mutare se calculează câștigul imediat obținut, care este numărul de conexiuni eliminate din setul de tăietură minus numărul de conexiuni care sunt adăugate în setul de tăietură prin această mutare. La sfârșitul etapei curente, se efectuează în mod efectiv mutările până în punctul în care se obține un câștig imediat maxim.

Câștigul probabilistic este util pentru determinarea nodurilor care vor fi mutate și care vor produce în final îmbunătățirea maximă a setului de tăietură, chiar dacă câștigul imediat al acelei mutări poate fi redus sau chiar negativ. Datorită unei asemenea mutări, este de așteptat ca o mutare viitoare să producă un câștig imediat de valoare mare. Acest mod de determinare a câștigurilor probabilistice, inițial și după fiecare mutare, este cheia pentru obținerea unor performanțe mai bune față de metodele de îmbunătățire iterativă deterministice sau bazate pe câștiguri imediate [69].

Algoritmul de partiționare pe baza câștigurilor probabilistice este descris în Figura 3.17.

Se descrie în continuare modul de calcul al câștigurilor probabilistice ale nodurilor din probabilitățile nodurilor. Pentru fiecare nod, se calculează câștigurile corespunzătoare fiecărei conexiuni din care face parte; câștigul total este suma acestor câștiguri ale conexiunilor. O conexiune n_i este numită *blocată* în V_1 (V_2) dacă fiecare nod din conexiune este blocat în V_1 (V_2). O conexiune este *blocată în setul de tăietură* dacă ea este blocată atât în V_1 , cât și în V_2 .

Pentru calculul câștigurilor nodurilor există două cazuri.

1) *Conexiunea se află în setul de tăietură*

Fie $u \in V_1$ care face parte din conexiunea n_i , conexiune aflată în setul de tăietură. Se notează setul $n_i \cap V_r$ prin $n_{i,r}$, $r = 1, 2$. Fie $n_i^{1 \rightarrow 2}$ ($n_i^{2 \rightarrow 1}$) evenimentul prin care n_i este eliminat din setul de tăietură prin mutarea tuturor nodurilor din $n_{i,1}$ ($n_{i,2}$) în V_2 (V_1). Se definește

$p(n_i^{1 \rightarrow 2} | u)$ = (probabilitatea ca n_i să fie eliminat din setul de tăietură prin mutarea tuturor nodurilor din $n_{i,1}$ în V_2 dacă u a fost mutat)

$p(n_i^{2 \rightarrow 1} | u^c) =$ (probabilitatea ca n_i să fie eliminat din setul de tăietură prin mutarea tuturor nodurilor din $n_{i,2}$ în V_1 dacă u nu a fost mutat)

Atunci câștigul $g_{n_i}(u)$ al nodului u corespunzător conexiunii n_i este definit ca

$$g_{n_i}(u) = c(n_i) [p(n_i^{1 \rightarrow 2} | u) - p(n_i^{2 \rightarrow 1} | u^c)] \quad (3.34)$$

unde $c(n_i)$ este costul (ponderea) conexiunii n_i .

```

Algorithm PROP (H);
/* H este hipergraful de partiționat */

begin
Pas. 1. Se partiționează H în două subseturi de dimensiuni egale (sau aproape egale)
      V1 și V2, în mod aleator sau utilizând tehnici de grupare;
      repeat
Pas 2.      Pentru fiecare nod u, se stabilește p(u) = pini, sau se determină
      p(u) din câștigurile deterministice ale nodurilor;
Pas 3.      Pentru fiecare nod, se calculează câștigurile pe baza ecuațiilor
      (3.37) și (3.38), și probabilitățile p(u);
      repeat
Pas 4.      Se selectează nodul u cu câștigul maxim din oricare subset
      pentru a fi mutat în celălalt subset dacă condiția de echilibru
      este satisfăcută. În caz contrar, se mută nodul u cu câștigul
      maxim pentru care condiția de echilibru nu este violată;
Pas 5.      Se memorează câștigul imediat al mutării curente;
Pas 6.      Se blochează toate nodurile mutate în iterația curentă, și
      se actualizează câștigurile nodurilor vecine care nu sunt
      blocate;
      until (toate nodurile sunt blocate, sau nu mai există mutări
      pentru care condiția de echilibru este satisfăcută);
Pas 7.      Se calculează sumele câștigurilor imediate ale tuturor mutărilor
      efectuate și se memorează maximum Gmax al acestor sume;
      if (Gmax > 0) then
        if (Gmax corespunde mutării p) then
          Se efectuează efectiv primele p mutări;
        endif
      else EXIT; endif;
      until (Gmax ≤ 0)
end.

```

Figura 3.17. Algoritmul PROP de partiționare pe baza câștigurilor probabilistice.

Motivul pentru termenul negativ din ecuația 3.34 este că mutarea nodului u previne apariția evenimentului $n_i^{2 \rightarrow 1}$, și astfel împiedică posibilitatea eliminării n_i din setul de tăietură în acest fel. Utilizând probabilități condiționate și faptul că cele mai multe conexiuni dintr-un circuit VLSI au un număr mic de noduri, se obține:

$$p(n_i^{1 \rightarrow 2} | u) \approx \prod_{u_x \in (n_{i,1} - \{u\})} p(u_x) \quad (3.35)$$

$$p(n_i^{2 \rightarrow 1} | u^c) \approx \prod_{u_y \in n_{i,2}} p(u_y) \quad (3.36)$$

Se obține astfel următoarea aproximare a câștigului $g_{n_i}(u)$ [70]:

$$g_{n_i}(u) \approx c(n_i) \left[\prod_{u_x \in (n_{i,1} - \{u\})} p(u_x) - \prod_{u_y \in n_{i,2}} p(u_y) \right] \quad (3.37)$$

2) Conexiunea nu se află în setul de tăietură

Se consideră acum contribuția la câștigul nodului u pe care o are conexiunea n_i care nu se află în setul de tăietură, și care nu este blocată în subsetul din care face parte, de exemplu V_1 . Conexiunea va fi introdusă în setul de tăietură atunci când u este mutat din V_1 în V_2 . Astfel, $g_{n_i}(u)$ va fi negativ și este dat de ecuația [70]:

$$g_{n_i}(u) \approx -c(n_i) \left(1 - \prod_{u_x \in n_{i,1} - \{u\}} p(u_x) \right) \quad (3.38)$$

După ce câștigurile inițiale ale fiecărui nod au fost calculate printr-una din metodele amintite, se calculează probabilitățile lor utilizând o funcție monoton crescătoare $p(u) = f(g(u))$ a câștigurilor acestora.

Există două probleme legate de calculul probabilităților. Prima este că, deoarece nu există certitudini în privința mutării nodurilor, este rezonabilă stabilirea unei probabilități maxime $p_{max} < 1$ și a unei probabilități minime $p_{min} > 0$, interval în care se află probabilitățile tuturor nodurilor. A doua problemă este de a stabili praguri superioare și inferioare ale câștigurilor g_{sup} și g_{inf} , astfel încât toate nodurile cu câștiguri mai mari sau egale cu g_{sup} vor avea probabilitatea p_{max} , iar cele cu câștiguri mai mici decât g_{inf} vor avea probabilitatea p_{min} . Motivul pentru stabilirea acestor praguri este că nodurile cu câștiguri mari, de exemplu mai mari decât 2, vor fi mutate necondiționat în celălalt subset, iar cele cu câștiguri foarte mici, de exemplu mai mici decât -1, cel mai probabil nu vor fi mutate în etapa curentă. Un exemplu de asemenea funcție este o funcție de probabilitate liniară între $p(u)$ și $g(u)$ atunci când $g_{inf} \leq g(u) \leq g_{sup}$.

Se descrie în continuare modul în care se actualizează nodurile care nu sunt blocate. Atunci când o conexiune n_i este blocată în V_2 , probabilitatea $p(n_i^{1 \rightarrow 2})$ este dată de ecuația 3.35, deoarece această probabilitate este condiționată implicit de mutările precedente din V_1 în V_2 ale nodurilor blocate în mod curent în $n_{i,2}$. De asemenea, în acest caz $p(n_i^{2 \rightarrow 1}) = 0$, deoarece $p(u) = 0$ pentru un nod blocat. Rezultă că atunci când n_i este blocat în V_2 , pentru un nod neblocat $u_x \in n_{i,1}$, $p(n_i^{1 \rightarrow 2} | u_x) = p(n_i^{1 \rightarrow 2}) / p(u_x)$, și deci

$$g_{n_i}(u_x) = c(n_i) \cdot p(n_i^{1 \rightarrow 2} | u_x) = c(n_i) \cdot p(n_i^{1 \rightarrow 2}) / p(u_x) \quad (3.39)$$

Pentru un nod neblocat u_y din $n_{i,2}$, unde n_i este blocat în V_2 , utilizând ecuația 3.37 și faptul că $p(n_i^{2 \rightarrow 1}) = 0$, se obține

$$g_{n_i}(u_y) = -c(n_i) \cdot p(n_i^{1 \rightarrow 2} | u_y^c) = -c(n_i) \cdot p(n_i^{1 \rightarrow 2}) \quad (3.40)$$

Se pot scrie expresii similare pentru cazul în care n_i este blocat în V_1 . Aceste ecuații sunt utile pentru actualizarea eficientă a nodurilor după o mutare.

După mutarea unui nod u , de exemplu din V_1 în V_2 , se actualizează mai întâi $p(n_i^{1 \rightarrow 2})$ și $p(n_i^{2 \rightarrow 1})$ pentru fiecare conexiune n_i din care face parte u . Se actualizează apoi câștigurile tuturor nodurilor care fac parte din fiecare asemenea conexiune n_i (vecinii nodului u), conform ecuațiilor 3.39 și 3.40. Apoi se setează $p(u) = 0$, indicând faptul că u este blocat. În final, se actualizează câștigurile unui număr redus de noduri, de exemplu 5, din cele clasate primele în fiecare subset, utilizând ecuațiile 3.37 și 3.38.

Această operație este necesară deoarece unele din aceste noduri pot fi vecini ai vecinilor nodului u , ale cărui probabilități au fost actualizate. Operația se execută numai pentru nodurile clasate primele, care sunt candidate pentru următoarea mutare, timpul necesar fiind mult mai redus decât pentru o actualizare completă.

Dacă n este numărul de noduri ale circuitului, p este numărul mediu de pini ai unui nod, q numărul mediu de pini pe conexiune, $d = p(q - 1)$ va fi numărul mediu de vecini ai unui nod. Se definește $m = pn = qe$ numărul total de pini ai circuitului, unde e este numărul de conexiuni. Complexitatea în privința timpului de execuție pentru o etapă a algoritmului PROP este $O(nd \log n) = O(mq \log n)$. Pentru circuitele VLSI, q este o constantă de valoare mică, de exemplu 4, și deci complexitatea este $O(m \log n)$ [69].

3.5 Partiționarea pentru circuitele FPGA

Atunci când dimensiunea circuitului proiectat este prea mare pentru a fi configurat într-un singur circuit FPGA, circuitul trebuie partiționat în subcircuite. Partiționarea circuitelor FPGA multiple trebuie să satisfacă restricții suplimentare asupra dimensiunii subcircuitelor și a numărului terminalelor de I/E. Pentru a ține cont de restricțiile suplimentare, au fost publicat un număr de algoritmi de partiționare pentru circuitele FPGA [40], [89], [101], [176].

McDermith a descris o metodă de partiționare de jos în sus pentru circuitele FPGA, în care funcțiile sunt selectate și plasate pe un cip, una câte una. Deoarece această metodă plasează în mod constructiv fiecare funcție, soluția nu este, în general, apropiată de cea optimă. Woo și Kim [176] au publicat un algoritm de îmbunătățire iterativă pentru circuitele FPGA. În fiecare etapă, celulele sunt mutate între blocuri și este aleasă partiția cea mai bună. Mutările sunt efectuate astfel încât să se reducă numărul de pini ai subcircuitelor sursă și/sau destinație.

Kuznar *et al.* au descris o metodă de partiționare a unui circuit de dimensiuni mari într-o colecție de subcircuite care pot fi implementate prin dispozitive selectate dintr-o bibliotecă dată. Fiecare dispozitiv din bibliotecă poate avea un cost, dimensiune și număr de terminale diferite.

Kim și Shin [101] au elaborat un algoritm de partiționare orientat pe performanțe, în scopul minimizării întârzierilor pe căile critice. Ei au studiat de asemenea partiționarea circuitelor pentru emularea logică prin circuite FPGA, elaborând un algoritm de partiționare a unui circuit care este emulat printr-o rețea de circuite FPGA. Pentru a asigura rutarea circuitului utilizând rețeaua FPGA, algoritmul ține cont de rutabilitate și de întârzierea unei căi estimată prin numărul de conexiuni între capsule.

Chan *et al.* [40] au descris o metodă spectrală de multipartiționare în care scopul principal este de a obține subcircuite rutabile, maximizând în același timp utilizarea circuitului FPGA. A fost dezvoltată o teorie de predicție a rutabilității subcircuitelor, înainte de partiționare.

Au fost publicat de asemenea algoritmi de partiționare pentru circuite FPGA bazate pe structuri de tip PLA. Hasan *et al.* [89] au elaborat un algoritm care partiționează în mod eficient o logică într-un număr minim de grupuri, astfel ca fiecare din acestea să poată fi implementat într-un bloc de tip PLA al circuitului FPGA.

3.5.1 Partiționarea ierarhică pentru circuite FPGA multiple

În această secțiune este descris un algoritm de partiționare orientat pe performanțe pentru implementarea sistemelor prin circuite FPGA multiple [101]. Intrarea furnizată algoritmului este o listă de conexiuni a unor blocuri ale unui circuit FPGA destinație. De exemplu, circuitele Xilinx au un singur tip de blocuri, numite CLB.

Fie un circuit cu n noduri (sau blocuri CLB) și fie V setul nodurilor, iar E setul conexiunilor, unde o conexiune $e \in E$ cuprinde două sau mai multe elemente din V . Problema de partiționare pentru circuite FPGA multiple poate fi definită formal după cum urmează.

Fiind dat un hipergraf $H(V, E)$, o funcție de cost f și un set de l circuite FPGA cu restricțiile de dimensiune și de pini S_1, \dots, S_l , respectiv P_1, \dots, P_l , trebuie să se găsească o mapare $\sigma: V \rightarrow \{1, 2, \dots, l\}$ astfel încât

- i. $a_i \leq S_i$ pentru fiecare $i = 1, 2, \dots, l$, unde $a_i = \{|\nu \mid \sigma(\nu) = i, \nu \in V\}$. De notat că dimensiunea fiecărui nod (CLB) este 1.
- ii. $b_i \leq P_i$ pentru fiecare $i = 1, 2, \dots, l$, unde b_i este numărul de conexiuni dintre un nod din subcircuitul i și un alt nod din subcircuitul $j \neq i$.
- iii. Funcția de cost f este minimizată.

Metodele de partiționare nu țin cont de obicei de întârzierile conexiunilor. Unul din principalele dezavantaje ale circuitelor FPGA față de circuitele ASIC este că viteza acestora este mult mai redusă datorită programabilității. De aceea, întârzierile semnalelor trebuie luate în considerare, iar întârzierile excesive trebuie penalizate în timpul partiționării.

În algoritmul elaborat de Kim și Shin, funcția de cost include atât dimensiunea tăieturii, cât și întârzierea introdusă de conexiune. Sunt estimate întârzierile pe căile critice, și se ține cont de acestea în timpul grupării și partiționării. Cea mai bună cale de a minimiza întârzierile pe o cale critică este de a se plasa toate nodurile căii respective în același circuit. De aceea, se pot grupa mai multe elemente apropiate conectate, grupul respectiv fiind considerat ca un obiect în timpul primei faze a partiționării. Măsura de apropiere dintre două elemente (noduri) conectate este reprezentată de o pondere a unei muchii.




Figura 3.18. Un exemplu de ponderare a căilor.

De exemplu, în Figura 3.18, fie (a, b, c, d, e) calea cea mai critică, cu întârzierea d_1 , muchiile aparținând acestei căi având ponderea w_1 . Dacă a doua cale critică este (f, c, d, e) , cu întârzierea d_2 , atunci muchia (f, c) are ponderea w_2 , unde $w_1 > w_2$. Ponderile sunt determinate astfel încât să normalizeze întârzierile căilor, după cum se arată în Figura 3.19.

Metoda de partiționare încearcă să minimizeze costul, satisfăcând în același timp restricțiile asupra numărului de terminale de I/E și asupra dimensiunii circuitelor. Algoritmul de partiționare constă din două faze. În prima fază, cea de partiționare inițială, se execută o partiționare ierarhică bazată pe grupare, care este modificată din [156]. Funcția obiectiv a primei faze este suma ponderată a dimensiunii tăieturii și a întârzierii maxime. Deoarece pentru minimizarea funcției obiectiv sunt mutate în mod iterativ noduri dintr-un subset în altul, ca și în cazul algoritmului Fiduccia-Mattheyses [76], rezultatul poate fi dependent de partiția inițială [156], [183]. Pentru a elimina această dependență, se partiționează grupurile de N ori pornind de la partiția inițială

generată aleator, și apoi se alege rezultatul cel mai bun. Acest rezultat este expandat și optimizat din nou pentru a finaliza faza de partiționare inițială.




Figura 3.19. Pondere conexiunilor în funcție de întârzierea căilor.

În faza a doua, cea de îmbunătățire a partiției, se îmbunătățește partiția obținută în prima fază pentru a satisface toate restricțiile datorate circuitelor FPGA date. Algoritmul de partiționare este prezentat în Figura 3.20.

```

Algorithm Part_FPGA_mult;
begin
    /* Partiționare inițială */
    Se generează grupuri;
    Se execută partiționarea grupurilor de  $NI$  ori;
    Se expandează cel mai bun rezultat obținut;
    Se partiționează blocurile CLB;

    /* Îmbunătățirea partiției */
    while ( $nr\_iterație < 3$  sau partiția este îmbunătățită în precedentele 3 iterații)
         $imbun\_part\_curentă()$ ;
    endwhile
end.

```

Figura 3.20. Algoritmul de partiționare pentru circuite FPGA multiple.

Pentru generarea grupurilor și partiționarea blocurilor CLB se utilizează metoda de partiționare cu forțarea graduală a restricțiilor GCEP [156]. La început, restricțiile de dimensiune sunt relaxate și dimensiunile subseturilor partiționate pot fi puternic dezechilibrate. Aceasta permite mutări foarte flexibile ale nodurilor între subseturi. După fiecare etapă de optimizare, restricțiile de dimensiune sunt forțate în mod gradual, astfel încât în etapa finală ele devin cele dorite. Astfel algoritmul GCEP efectuează o căutare într-un spațiu mai larg al soluțiilor.

Algoritmul utilizat pentru partiționarea grupurilor și a blocurilor CLB este descris în Figura 3.21. O celulă este un grup de blocuri CLB pentru partiționarea grupurilor și este un bloc CLB pentru partiționarea blocurilor CLB. K este numărul de circuite (sau grupuri).

Îmbunătățirea partiției este executată pe baza câștigului (reducerii costului) în urma mutării unui bloc CLB de la un circuit la un altul. Mutările sunt efectuate în ordinea descrescătoare a câștigurilor. Violările restricțiilor asupra numărului de blocuri CLB și de pini sunt reflectate în cost prin adăugarea unor termeni de penalizare. Atunci când există violări rămase la sfârșitul unei iterații, valorile de penalizare pentru

restricțiile violate sunt mărite. Dacă rezultatul violat nu este îmbunătățit în timpul a trei iterații consecutive, algoritmul se termină.

Funcția de cost care cuprinde și termenii de penalizare se poate scrie astfel:

$$cost = dim_tăietură + r \cdot cost_întârziere + \alpha \cdot depășire_CLB + \beta \cdot depășire_pin$$

unde r este un factor de ponderare. Valorile lui α și β sunt ajustate în mod dinamic. Ultimii doi termeni devin zero atunci când restricțiile asupra numărului de blocuri CLB și a numărului de pini sunt satisfăcute.

Algoritmul de îmbunătățire a partițiilor este similar cu cel de partiționare inițială. Diferențele constau din următoarele: 1) restricțiile de dimensiune nu sunt relaxate; 2) α este mărit cu unu dacă numărul de blocuri CLB este violat pentru un subcircuit (grup), iar β este mărit cu unu dacă numărul de pini este violat, după fiecare execuție a procedurii de îmbunătățire; 3) blocurile CLB sunt mutate numai dacă câștigul este pozitiv; 4) bucla principală de optimizare se termină atunci când numărul de violări sau costul nu sunt îmbunătățite în timpul a trei iterații consecutive.

```

Algorithm GCEP;
begin
    partiționare_inițială;
    evaluare_câștig_inițial;
    grup_curent = 1;
    echilibru = ECHIL_INIT; /* ECHIL_INIT = 0.5 */
    dim_dif = dim_med × echilibru;
    for (TRUE) do
        /* Istoria mutărilor și câștigurile sunt memorate în lista_mutări */
        /* Mutare în exterior cât timp dimensiunea grup_curent
        nu este mai mică decât (dim_med - dim_dif) */
        move_ext (grup_curent, dim_dif);
        /* Mutare în interior cât timp dimensiunea grup_curent
        nu este mai mare decât (dim_med + dim_dif) */
        move_int (grup_curent, dim_dif);
        /* Găsește punctul optim din lista_mutări și anulează
        mutările efectuate după acest punct */
        undo_move;
        grup_curent ++;
        /* Dacă o iterație este terminată */
        if (grup_curent == K + 1) then
            grup_curent = 1;
            echilibru = echilibru × RATA_REDOCERE;
            /* RATA_REDOCERE = 0.9 */
            if (echilibru ≤ ECHIL_FINAL) then
                /* ECHIL_FINAL = 0.2 */
                break; /* Partiționare terminată */
            endif;
            dim_dif = dim_med × echilibru;
            if (dim_dif < dim_med × ECHIL_FINAL) then
                dim_dif = dim_med × ECHIL_FINAL;
            endif
        endif
    endfor
end.

```

Figura 3.21. Algoritmul de partiționare cu formarea graduală a restricțiilor.

3.5.2 Partiționarea pentru circuite FPGA cu structuri de tip PLA

Maparea unor ecuații booleene într-un număr minim de circuite este o sarcină dificilă. O parte a acestei probleme o reprezintă partiționarea logicii în numărul minim de structuri PLA (*Programmable Logic Array*) de dimensiune fixă. Există un număr mic de lucrări legate de partiționarea logicii pentru arhitecturi de tip PLA. Hasan *et al.* [89] au elaborat o metodă pentru multipartiționarea unei funcții logice cu ieșiri multiple într-un număr minim de subfuncții pentru maparea în structuri PLA de dimensiune fixă sau blocuri funcționale ale unui circuit FPGA.

Fiind dat un set de ecuații booleene, problema este de a le partiționa într-un număr minim de grupuri, astfel încât fiecare din acestea să poată fi implementat într-un bloc funcțional al circuitului. Obiectivul este de a se minimiza numărul de blocuri funcționale utilizate de mapare.

Fiecărei funcții de ieșire i se asociază un cost, reprezentând restricțiile pe care le impune pentru algoritmul de partiționare. Restricțiile pentru blocurile funcționale sunt numărul limitat de intrări și termeni produs partajați de o ieșire. Costul se exprimă ca o combinație ponderată a acestor restricții. Astfel, costul C_n al ieșirii n se calculează astfel:

$$C_n = W_i I_n + W_p P_n$$

unde W_i și W_p sunt ponderile restricțiilor pentru numărul de intrări, respectiv pentru numărul termenilor produs. I_n și P_n sunt numărul de intrări, respectiv numărul de termeni produs partajați de ieșirea n . Din experimente rezultă că trebuie să se aleagă o valoare mai mare pentru ponderea W_i , deoarece aceasta are tendința să grupeze ieșirile cu intrări comune și să crească numărul termenilor produs partajați.

Următoarele trei condiții determină dacă o funcție de ieșire poate fi implementată într-un bloc funcțional.

- Fiecare bloc funcțional are un număr limitat de linii de ieșire. Dacă numărul liniilor de ieșire dintr-un bloc este O_m , blocul poate implementa numai O_m ieșiri.
- Fiecare bloc funcțional are un număr limitat de linii de intrare. Fie numărul liniilor de intrare ale unui bloc funcțional I_m . Dacă ieșirile curente din bloc utilizează x linii de intrare, o nouă ieșire poate fi implementată în acel bloc numai dacă necesită un număr de noi linii de intrare $\leq (I_m - x)$. Noile intrări sunt cele care nu sunt conectate deja la blocul în cauză.
- Fiecare bloc funcțional poate avea numai P_m termeni produs partajați. Dacă ieșirile existente în blocul funcțional utilizează y termeni produs partajați, o nouă ieșire poate fi implementată în acel bloc numai dacă necesită un număr de noi termeni produs $\leq (P_m - y)$.

O nouă ieșire poate fi implementată într-un bloc funcțional numai dacă satisface toate cele trei condiții.

Pentru minimizarea numărului total de termeni produs utilizați de o funcție se pot utiliza utilitare de minimizare logică, de exemplu *Espresso* (dezvoltată la Universitatea din California, Berkeley). Minimizarea întregii funcții înainte de partiționare poate face însă imposibilă utilizarea termenilor partajați care sunt generați astfel, deoarece distribuția ieșirilor între diferite blocuri va necesita duplicarea termenilor produs partajați. Minimizarea efectuată după partiționare este inutilă, deoarece ieșirile vor putea fi implementate în blocurile respective chiar și fără minimizare. Această problemă a fost rezolvată în [89] prin următorul procedeu:

Se începe prin efectuarea unei partiționări de tip greedy cu restricții relaxate, pentru a se obține blocurile partiției inițiale. Prin partiționare de tip greedy se înțelege aici alegerea setului cel mai mare de ieșiri care pot fi implementate într-un bloc. Re-

restricțiile fiind relaxate, este posibil ca $O_i > O_m$ și $P_i > P_m$, unde O_i și P_i sunt parametrii care definesc dimensiunea blocului funcțional. Inițial se alege un număr mai mare de ieșiri decât cel maxim implementabil, și se minimizează acel grup de ieșiri. Se aleg apoi O_m ieșiri din grupul minimizat. Blocurile partiției inițiale conțin un număr mai mare de termeni produs partajați. Se așteaptă ca numărul termenilor produs partajați să scadă în timpul procedurii de minimizare.

Pentru procedura de partiționare de tip greedy se consideră următorul set de parametri pentru dimensiunea unui bloc funcțional: numărul liniilor de ieșire O , numărul liniilor de intrare I , și numărul termenilor produs partajați disponibili P . Procedura încearcă să selecteze O ieșiri care pot fi implementate într-un bloc funcțional. Inițial, se selectează prima ieșire din baza de date și se asignează primului bloc.

Baza de date este aranjată în ordine descrescătoare a costurilor ieșirilor; astfel, ieșirea cea mai costisitoare va fi asignată primului bloc. Procedura selectează apoi următoarea ieșire cea mai costisitoare din baza de date și verifică dacă această ieșire satisface restricțiile pentru numărul de intrări și numărul termenilor produs. În caz afirmativ, ieșirea va fi asignată la acel bloc. Procedura se termină atunci când a plasat O ieșiri în primul bloc sau când nu mai există noi ieșiri care pot fi asignate aceluși bloc.

```

Procedure rafinare ( $O, I, P, bloc$ );
begin
Pas 1. Se elimină ieșirea cea mai puțin costisitoare;
Pas 2. Se încearcă adăugarea unor noi ieșiri;
Pas 3. if ( $nr\_ieșiri \leq n$ ) then
        Se înlocuiește ieșirea din bloc;
        Se elimină următoarea ieșire cea mai puțin costisitoare;
        if (următoarea ieșire cea mai puțin costisitoare =
            ieșirea cea mai costisitoare) then
            Se înlocuiește ieșirea din bloc;
            goto Pas 6;
        endif;
    endif;
Pas 4. if ( $nr\_ieșiri > n$ ) then
        Se elimină ieșirea în mod permanent din această partiție;
    endif;
Pas 5. if ( $nr\_ieșiri = O$ ) then
        goto Pas 6;
    else
        goto Pas 1;
    endif;
Pas 6. return;
end

```

Figura 3.22. Procedura de rafinare.

După procedura de partiționare de tip greedy se execută o procedură de rafinare. Aceasta are următorii parametri de intrare: O, I, P , și un bloc valid de ieșiri (o partiție). Un bloc valid de ieșiri este cel care poate fi implementat într-un bloc funcțional al circuitului. Presupunem că primul bloc are n ieșiri: O_1, O_2, \dots, O_n , unde $n < O$. Aceste ieșiri sunt sortate în ordinea descrescătoare a costului. Procedura presupune că o ieșire în această partiție utilizează toate resursele, prevenind asignarea altor ieșiri la acel bloc. Se încearcă eliminarea acelei ieșiri din bloc în felul următor: Se elimină temporar ieșirea cea mai puțin costisitoare, O_n , din bloc, și se încearcă potrivirea unor noi ieșiri în bloc. În acest caz, pot apare două situații:

- Nu se poate găsi nici o nouă ieșire care poate fi potrivită în acel bloc; deci, există acum $(n - 1)$ ieșiri în blocul respectiv. Aceasta înseamnă că ieșirea O_n nu a prevenit asignarea unor noi ieșiri la acel bloc. De aceea se plasează înapoi ieșirea O_n în blocul funcțional, se elimină temporar ieșirea O_{n-1} , și se încearcă din nou potrivirea unor noi ieșiri în bloc. Procedura se continuă până când se ajunge la ieșirea O_1 (cea mai costisitoare din bloc). Aceasta nu se elimină din bloc, și procedura se termină.
- Se poate găsi o nouă ieșire care poate fi potrivită în acel bloc; deci, există acum un număr $\geq n$ de ieșiri în bloc. Aceasta înseamnă că ieșirea care a fost eliminată temporar va fi eliminată permanent din bloc. Se revine apoi la primul pas al procedurii.

Procedura se termină dacă există numărul maxim de ieșiri permise în bloc sau dacă s-a încercat eliminarea tuturor ieșirilor cu excepția celei mai costisitoare. Procedura de rafinare este descrisă în Figura 3.22.

Întregul algoritm de partiționare poate fi descris astfel:

1. Se execută *partiționare_greedy* (O_i, I_m, P_i);
2. Dacă $n < O_i$ se apelează procedura *rafinare*;
3. Se minimizează ieșirile selectate;
4. Se selectează O_m ieșiri utilizând *partiționare_greedy* și *rafinare*, și aceste ieșiri nu vor fi luate în considerare în continuare;
5. Se continuă cu pasul 1 până când nu mai există ieșiri care trebuie partiționate;
6. Se execută *rafinare_finală*.

După sortarea tuturor ieșirilor în ordine descrescătoare a costurilor, algoritmul de partiționare începe cu pasul de partiționare de tip greedy. Procedurii de partiționare greedy i se transmit următorii parametri: $O = O_i, I = I_m, P = P_m$, unde $O_i > O_m$ și $P_i > P_m$. Restricțiile au fost deci relaxate în această etapă pentru a executa pasul de minimizare. La sfârșitul pasului de partiționare greedy, se testează numărul ieșirilor din primul bloc. Dacă acest număr este mai mic decât O_i , se execută procedura de rafinare. Apoi se minimizează ieșirile astfel generate. Pot exista însă mai mult de O_m ieșiri în acest bloc. De aceea se execută din nou procedurile de partiționare greedy și rafinare asupra acestui grup mai mic de ieșiri. Se utilizează parametrii $O = O_m, I = I_m$ și $P = P_m$ pentru a obține primul bloc care poate fi implementat într-un bloc funcțional.

Se marchează ieșirile din primul bloc ale partiției ca fiind eliminate, și se repetă întreaga procedură pentru ieșirile rămase. Cele $O_i - O_m$ ieșiri, care nu sunt asignate la primul bloc, nu sunt marcate ca fiind eliminate. Această procedură se repetă până când toate ieșirile vor fi plasate într-o partiție validă. În această etapă se apelează procedura de rafinare finală, care încearcă mutarea unor ieșiri dintr-un bloc în altul pentru a crește densitatea logică a blocurilor.

Algoritmul descris execută partiționarea cu minimizarea logicii, optimizând utilizarea blocurilor PLA disponibile în cadrul circuitului. Acest algoritm a fost elaborat pentru circuitele Xilinx din seria 7200, dar poate fi utilizat pentru orice circuit cu o arhitectură similară de tip PLA.

3.6 Metode neconvenționale de partiționare

În literatură au fost raportate un număr relativ redus de soluții ale problemei de partiționare a circuitelor, obținute prin tehnici neconvenționale, ca algoritmi ge-

netici, automate de învățare sau rețele neuronale. Saab și Rao [145], [189] au utilizat metodologia de evoluție stohastică pentru soluționarea problemei de bipartiționare la care nodurile circuitului au dimensiuni diferite. Aceeași autori au extins algoritmul de bipartiționare prin evoluție stohastică pentru problema de multipartiționare, în care diferitele subseturi ale partiției cu k căi sunt considerate simultan, și nu două câte două. În secțiunea 3.6.1 se prezintă un algoritm general care utilizează metodologia de evoluție stohastică, și apoi adaptarea acestui algoritm pentru soluționarea problemelor de bipartiționare și multipartiționare a circuitelor.

Bui și Moon [31], [32] au publicat un algoritm genetic hibrid pentru partiționarea grafurilor, care conține și o euristică rapidă de îmbunătățire locală. La începutul algoritmului se execută o fază de preprocesare a schemelor, care reordonează pozițiile vârfurilor în cadrul cromozomilor, cu scopul de a îmbunătăți posibilitățile algoritmului de căutare în spațiul soluțiilor. Algoritmul este descris în secțiunea 3.6.2, care prezintă de asemenea terminologia utilizată de algoritmi genetici și structura generală a unui asemenea algoritm.

Oommen și St. Croix [129] au utilizat automatele de învățare pentru partiționarea grafurilor. Aceștia au propus o metodă în care problema de partiționare a grafurilor este rezolvată prin considerarea acesteia ca o problemă de partiționare a obiectelor. În secțiunea 3.6.3 este prezentat un automat de învățare pentru partiționarea grafurilor.

Yih și Mazumder au utilizat rețele neuronale pentru bipartiționarea circuitelor [146]. Bipartiționarea este reprezentată sub forma stărilor rețelei neuronale. Criteriul de selecție a componentelor care își vor modifica poziția este descris în termenii conexiunilor neuronilor și a ponderilor corespunzătoare între neuroni. Este utilizat paralelismul masiv al rețelelor neuronale, rezultatele obținute fiind comparabile cu cele ale euristicii Fiduccia-Mattheyses. În capitolul 4 se va prezenta utilizarea rețelelor neuronale pentru rezolvarea problemei de plasare a componentelor.

3.6.1 Partiționarea prin evoluție stohastică

Metodologia de evoluție stohastică (*Stochastic Evolution - SE*) utilizează analogia dintre tehnicile de îmbunătățire iterativă și evoluția biologică, executând pași selectați în mod arbitrar. În evoluția biologică, speciile elimină unele din caracteristicile nedorite ale vechii generații pe măsură ce ele evoluează de la o generație la alta. În acest proces, fiecare membru al speciei decide să rețină caracteristicile sale în mediul curent sau să le modifice. Atunci când se utilizează această metodă, soluția curentă a problemei de optimizare este considerată ca fiind generația curentă. Caracteristicile nedorite ale soluției curente sunt identificate și eliminate pentru a genera o soluție mai bună.

Algoritmii *SE* aparțin clasei euristiciilor adaptive, ca și călirea simulată. Un algoritm adaptiv utilizează un set de parametri de control care sunt modificați fie de utilizator, fie de algoritmul însuși. Astfel, algoritmul se adaptează problemei particulare. Adaptarea parametrilor afectează calitatea soluției rezultate. Pentru a se utiliza evoluția stohastică, trebuie definită o funcție de cost care măsoară calitatea soluției. Spre deosebire de călirea simulată, funcția de cost în cazul evoluției stohastice poate fi sub forma unui vector, și se poate utiliza o relație de ordonare pentru a se compara diferenții vectori de cost.

În Figura 3.23 se prezintă un algoritm general de tip *SE* [189]. Acest algoritm poate fi aplicat pentru o mare varietate de probleme de combinatorică.

Parametrii de intrare ai algoritmului *SE* constau dintr-o soluție inițială S_0 , o valoare inițială a parametrului de control p_0 , și un parametru R care controlează numărul de iterații. Algoritmul reține soluția cu costul minim dintre cele produse de funcția *Perturb*. De fiecare dată când se găsește o soluție cu un cost mai mic decât soluția

curentă cea mai bună, algoritmul decrementează contorul prin R , recompensându-se astfel prin creșterea numărului de iterații.

În procesul de evoluție al speciilor biologice, fiecare caracteristică a unei specii din generația curentă trebuie să demonstreze că mediul acesteia nu trebuie schimbat în generația următoare. Funcția *Perturb* implementează această caracteristică prin cerința ca fiecare nod al circuitului să demonstreze că nu trebuie să-și schimbe subsetul din care face parte în următoarea partiție generată de algoritm.

```

Algorithm SE ( $S_0, p_0, R$ );
begin
     $S = S_0$ ;                                /* soluția inițială */
     $S_{best} = S$ ;
     $C_{best} = Cost(S)$ ;
     $p = p_0$ ;                                /* inițializare parametru de control */
     $contor = 0$ ;
    repeat
         $C_{pre} = Cost(S)$ ;
         $S = Perturb(S, p)$ ;
         $C_{curent} = Cost(S)$ ;
        Update ( $p, p_0, C_{pre}, C_{curent}$ );
        if ( $C_{curent} < C_{best}$ ) then
             $S_{best} = S$ ;                    /* salvează soluția cea mai bună */
             $C_{best} = C_{curent}$ ;
             $contor = contor - R$ ;
        else
             $contor = contor + 1$ ;
        endif;
    until ( $contor > R$ );
    return ( $S_{best}$ );
end.

```

Figura 3.23. Structura unui algoritm de evoluție stohastică.

Funcția *Perturb* scanează nodurile circuitului într-o anumită ordine. Fie $P = (V_1, \dots, V_k)$ partiția curentă atunci când este scanat nodul i . În această etapă, este sugerată o mutare constând din transferul nodului i din subsetul său curent P într-un nou subset, și se evaluează un câștig $GAIN(i)$ pentru această mutare. Fie P' partiția rezultată astfel. Funcția *Perturb* decide dacă acceptă sau nu mutarea sugerată. Această decizie este luată în mod stohastic cu ajutorul unui parametru de control non-positiv p . Valoarea $GAIN(i)$ este comparată cu un întreg aleator r cu valori în intervalul $[p, 0]$. Dacă $GAIN(i) > r$, partiția P' înlocuiește partiția curentă P , în caz contrar se reține partiția curentă P . După scanarea tuturor nodurilor, *Perturb* poate decide inversarea sau schimbarea unora din ultimele mutări acceptate.

Procedura *Update* decrementează parametrul de control p ori de câte ori se suspectează faptul că algoritmul este blocat într-un minim local. Fie C_{pre} și C_{curent} costul partiției curente înainte, respectiv după apelul funcției *Perturb*. Costul unei partiții poate fi un vector. Dacă $C_{pre} = C_{curent}$, parametrul p este decrementat cu 1; în caz contrar, p este resetat la valoarea sa inițială p_0 . Valoarea inițială p_0 este de obicei un întreg negativ apropiat de 0, de exemplu -1.

Parametrul R controlează numărul de iterații, și are rolul numărului așteptat de iterații necesare până când se găsește o partiție care este mai bună decât cele găsite până în acel moment. Dacă o îmbunătățire apare după $contor < R$ iterații, $contor$ este decrementat cu R . Astfel, algoritmul va mai putea executa încă $R - contor$ iterații. În consecință, dacă T este numărul total de iterații ale algoritmului, numărul de îmbunătățiri întâlnite este T/R .

3.6.1.1 Bipartiționarea prin evoluție stohastică

De obicei, algoritmi de bipartiționare nu pot trata în mod eficient cazul nodurilor cu dimensiuni diferite. Se prezintă în continuare adaptarea algoritmului *SE* pentru soluționarea problemei de bipartiționare la care nodurile circuitului au dimensiuni diferite [145], [189]. Acest algoritm, numit *2_SE*, poate fi complet specificat prin indicarea partiției inițiale și a funcției *Perturb*.

Generarea partiției inițiale este prezentată în Figura 3.24.

Fiind dată o partiție inițială (V_1, V_2) , mutarea asociată cu fiecare nod i este reprezentată de transferul acestui nod din subșetul său curent în subșetul complementar al partiției. De exemplu, dacă $i \in V_1$, mutarea asociată cu i determină noua partiție $(V_1 - \{i\}, V_2 \cup \{i\})$. Câștigul $GAIN(i)$ asociat cu fiecare nod i este reducerea dimensiunii tăieturii atunci când este executată mutarea asociată cu nodul i . Câștigul unui nod poate fi negativ sau pozitiv.

```

Procedure Part_init;
begin
  Fie  $l_1, \dots, l_n$  nodurile sortate în ordinea descrescătoare a dimensiunii;
   $V_1 = V_2 = \emptyset$ ;
   $S(V_1) = S(V_2) = 0$ ;
  for ( $i = 1$  to  $n$ ) do /*  $n$  este numărul de noduri */
    if ( $S(V_1) < S(V_2)$ ) then
       $V_1 = V_1 \cup \{l_i\}$ ;
       $S(V_1) = S(V_1) + s(l_i)$ ;
    else
       $V_2 = V_2 \cup \{l_i\}$ ;
       $S(V_2) = S(V_2) + s(l_i)$ ;
    endif;
  endfor;
  return  $(V_1, V_2)$ ;
end

```

Figura 3.24. Generarea partiției inițiale pentru algoritmul *2_SE*.

Funcția *Perturb* constă din doi pași: selecție și interschimbare.

Pasul de selecție începe prin scanarea tuturor nodurilor în ordine descrescătoare a dimensiunii și prin inițializarea a două seturi A_1 și A_2 ca seturi vide. Atunci când este scanat nodul i , $GAIN(i)$ este comparat cu un întreg aleator r în intervalul $[r, 0]$. Dacă $GAIN(i) > r$, nodul i dorește mutarea în subșetul complementar. În acest caz, dacă $i \in V_1$, i este mutat în V_2 și este inclus în A_1 . Dacă $i \in V_2$, i este mutat în V_1 și este inclus în A_2 . După executarea unei mutări, câștigurile tuturor nodurilor sunt actualizate. Astfel, după scanarea tuturor nodurilor, setul A_1 conține un subșet de noduri din V_1 care au fost mutate în V_2 , iar A_2 conține un subșet de noduri din V_2 care au fost mutate în V_1 . Scopul acestui pas este de a minimiza dimensiunea tăieturii partiției.

În pasul de interschimbare, este permisă menținerea doar a unui subșet B_k de noduri din A_k în V_{3-k} pentru fiecare $k = 1, 2$. Seturile B_1 și B_2 sunt alese astfel încât noua partiție $(V_1 \cup B_2 - B_1, V_2 \cup B_1 - B_2)$ să aibă un echilibru mai bun al dimensiunii față de vechea partiție (V_1, V_2) . În acest pas principalele operații sunt executate de funcția *Echilibru*, descrisă în continuare.

Scopul funcției *Echilibru* este de a produce o nouă partiție cu un echilibru mai bun al dimensiunii. Fie (V_1, V_2) o partiție dată, astfel încât V_1 este partea cea mai mare a partiției. Fie $S(V_1) - S(V_2) = x > 0$. Este de dorit ca algoritmul să selecteze pentru interschimbare un subșet $B_1 \subseteq A_1$ și $B_2 \subseteq A_2$ astfel încât $|S(B_1) - S(B_2) - x|$ să fie

minim. Această problemă de alegere a subseturilor B_1 și B_2 este NP-completă [189]. Funcția *Echilibru* rezolvă un caz special al acestei probleme ținând cont de faptul că în pasul de selecție un nod care este selectat pentru mutarea în subsetul complementar afectează câștigurile altor noduri. De aceea, funcția *Echilibru* preferă pentru inter schimbare nodurile selectate anterior față de cele selectate recent. Dacă $A_1 \cup A_2 \neq \emptyset$, funcția garantează că $B_1 \cup B_2 \neq \emptyset$. Astfel, diferența între dimensiunile celor două părți poate crește, dar aceasta asigură algoritmului o probabilitate mai ridicată de a evita minimele locale.

Parametrii de intrare ai funcției *Echilibru* sunt două tablouri $A_1[]$ și $A_2[]$ de noduri sortate în ordinea descrescătoare a dimensiunilor, și un întreg x . Fie a_1 și a_2 numărul elementelor din tablourile A_1 , respectiv A_2 . Se presupune că tabloul $A_1[]$ conține noduri din subsetul mai mare. Funcția *Echilibru* determină numerele întregi non-negative k și l astfel încât $|S(B_1) - S(B_2) - x|$ este minimizat, unde $B_1 = \{A_1[1], \dots, A_1[k]\}$, iar $B_2 = \{A_2[1], \dots, A_2[l]\}$. Cazurile de egalitate sunt rezolvate prin alegerea celui mai mare k și l posibil. Dacă $k = 0$, atunci B_1 este vid. Similar, dacă $l = 0$, atunci B_2 este vid.

Funcția *Echilibru* este descrisă în Figura 3.25.

```

Procedure Echilibru ( $a_1, a_2, A_1, A_2, x$ );
begin
     $SA1 = 0$ ;
     $SA2 = 0$ ;
     $MIN = \infty$ ;
     $k = 0$ ;
     $l = 0$ ;
     $j = 0$ ;
    for ( $j = 0$  to  $a_1$ ) do
         $SA1 = SA1 + s(A_1[j])$ ;
         $min = |SA1 - SA2 - x|$ ;
         $\hat{im}bun\hat{a}t\hat{a}t\hat{i}re = FALSE$ ;
        if ( $a_2 \neq 0$ ) then  $\hat{im}bun\hat{a}t\hat{a}t\hat{i}re = TRUE$ ; endif;
        while ( $(j \leq a_2)$  and ( $\hat{im}bun\hat{a}t\hat{a}t\hat{i}re$ )) do
             $\hat{im}bun\hat{a}t\hat{a}t\hat{i}re = FALSE$ ;
             $w = |SA1 - SA2 - x - s(A_2[j+1])|$ ;
            if ( $w < min$ ) then
                 $min = w$ ;
                 $j = j + 1$ ;
                 $SA2 = SA2 + s(A_2[j])$ ;
                 $\hat{im}bun\hat{a}t\hat{a}t\hat{i}re = TRUE$ ;
            endif;
        endwhile;
        if ( $min \leq MIN$ ) then
             $MIN = min$ ;
             $k = j$ ;
             $l = j$ ;
        endif
    endfor;
    return ( $k, l$ );
end

```

Figura 3.25. Procedura *Echilibru* pentru algoritmul 2_SE.

Execuția funcției *Echilibru* necesită un timp liniar, deoarece i și j nu sunt decrementate niciodată. Motivul pentru care j nu este decrementat este următorul. Presupunem că pentru un i dat, j este întregul pentru care $|SA1 - SA2 - x|$ este minim.

Atunci, pentru $i' > i$, întregul j' care minimizează $|SA1 - SA2 - x|$ trebuie să satisfacă inegalitatea $j' > j$. De notat că $SA1 = \sum_{l=1}^i s(A_1[l])$ și $SA2 = \sum_{l=1}^j s(A_2[l])$.

În pasul de selecție, nodurile sunt scanate în ordinea descrescătoare a dimensiunilor, astfel că tablourile A_1 și A_2 pot fi construite într-un timp liniar fără sortare, iar ordinea elementelor lor reflectă ordinea în care nodurile au fost selectate.

Algoritmul 2_SE poate fi modificat pentru a ține cont de ponderile diferite ale conexiunilor, sau pentru rezolvarea unor probleme similare cu bipartiționarea, cum este problema de bisecție a conexiunilor [189].

3.6.1.2 Multipartiționarea prin evoluție stohastică

Una din metodele prin care poate fi realizată multipartiționarea cu k căi este de a aplica în mod recursiv algoritmul de bipartiționare. Această metodă are însă un dezavantaj important. La primul nivel, algoritmul de bipartiționare încearcă să minimizeze dimensiunea tăieturii. Deoarece minimizarea dimensiunii tăieturii este echivalentă cu maximizarea numărului de conexiuni interne din ambele părți, partiționarea la primul nivel va fi în conflict cu partiționarea la al doilea nivel, unde algoritmul de bipartiționare va încerca să minimizeze dimensiunea tăieturii pentru un set de noduri puternic conectate. Această metodă recursivă de partiționare executată pe mai multe nivele poate genera o soluție globală de calitate redusă.

O altă metodă de multipartiționare este de a se începe cu anumite partiții inițiale de k părți. Apoi, se poate utiliza un algoritm de bipartiționare pentru a optimiza numărul de conexiuni tăiate între fiecare pereche de subseturi ale partiției cu k căi. Dezavantajul acestei metode este faptul că nu sunt considerate interschimbări mai complexe ale nodurilor între mai mult de două subseturi ale partiției originale cu k căi. Este necesară o interschimbare mai complexă a nodurilor pentru a reduce dimensiunea tăieturii.

Algoritmul de evoluție stohastică se poate utiliza și pentru rezolvarea problemei de partiționare cu k căi. În acest caz, diferitele subseturi ale partiției cu k căi vor fi considerate simultan, și nu două câte două. Saab și Rao [189] au elaborat un algoritm numit k_SE pentru rezolvarea următoarei probleme de partiționare cu k căi:

Fiind dat un set de noduri V , un set de conexiuni N_1, \dots, N_n între ele, un subset de conexiuni numit $TEST$, o dimensiune $s(i)$ pentru fiecare $i \in V$, o pondere $W(N_j)$ pentru fiecare conexiune N_j , o limită a dimensiunii S , și o limită a numărului de pini E , să se găsească o partiție (V_1, \dots, V_k) care minimizează

$$\left(|\{V_i: S(V_i) < S\}|, |\{V_i: E_i < E\}|, \sum_{i=1}^n W(N_i)C(N_i) \right) \quad (3.41)$$

astfel încât fiecare conexiune din setul de testare $TEST$ este tăiată. În formularea acestei probleme, fiind date limitele S și E , costul unei partiții (V_1, \dots, V_k) , este vectorul:

$$COST(V_1, \dots, V_k) = \left(|\{V_i: S(V_i) < S\}|, |\{V_i: E_i < E\}|, \sum_{i=1}^n W(N_i)C(N_i) \right) \quad (3.42)$$

Algoritmul k_SE rezolvă această problemă prin execuția următorilor pași:

1. Se determină numărul de părți în care se divide circuitul.
2. Conexiunile din setul $TEST$ sunt păstrate externe prin blocarea unora din nodurile lor în diferitele părți ale partiției. Nodurile blocate nu pot fi mutate într-o altă parte.

3. Se rezolvă problema de bipartiționare prin evoluție stohastică considerând nodurile care nu sunt blocate.

Numărul inițial de părți în care se divide circuitul este determinat prin simularea unui algoritm de împachetare. Intrările pentru acest algoritm sunt nodurile în ordinea descrescătoare a dimensiunii, și o limită a dimensiunii S . Algoritmul presupune că există un număr infinit de recipiente, fiecare având o capacitate S . Pe măsură ce un nod este scanat, acesta este împachetat în primul recipient a cărui dimensiune este suficientă pentru nodul respectiv.

Presupunem că numărul de părți determinat în primul pas este k , deci setul de noduri trebuie partiționat în k subseturi V_1, \dots, V_k . Fie $T = \bigcup_{N \in TEST} N$ setul tuturor nodurilor care aparțin cel puțin unei conexiuni testabile. Pentru a asigura ca fiecare conexiune din $TEST$ să fie externă, trebuie blocat un subset $L \subseteq T$ de noduri din T în diferitele subseturi V_1, \dots, V_k astfel încât fiecare conexiune din $TEST$ să aibă o intersecție nevidă cu cel puțin două din subseturile V_1, \dots, V_k , și $S(V_i) \leq S$ ($i = 1, \dots, k$). Fiecare nod din L , după ce este blocat într-unul din subseturile V_1, \dots, V_k , nu poate fi mutat într-un subset diferit în etapele viitoare ale algoritmului. De aceea, este de dorit ca numărul nodurilor din setul L să fie cât mai mic posibil.

Fie $G_i = \{N : N \in TEST, i \in N\}$ subsetul de conexiuni testabile care conțin nodul $i \in T$, și fie $\rho(i) = |G_i|$ cardinalitatea lui G_i . Pentru fiecare $i \in T$ și subset V_j fie $a_{ij} = |\{N : N \in G_i, N \cap V_j = \emptyset\}|$ numărul de conexiuni din G_i care nu se intersectează cu V_j . Numărul a_{ij} poate fi considerat ca atracția pe care partea V_j o exercită asupra nodului i . Inițial, $a_{ij} = \rho(i)$, $j = 1, \dots, k$, dar pe măsură ce fiecare din nodurile lui T este blocat într-una din părțile V_1, \dots, V_k , valorile a_{ij} se modifică. Fie t_1, \dots, t_q setul nodurilor din T aranjate astfel încât $u < v$ implică $\rho(t_u) \geq \rho(t_v)$. Pentru determinarea subsetului de noduri care trebuie blocate se poate utiliza următoarea euristică [189]:

1. Se setează $i = 1$.
2. Se determină j care maximizează $a_{t_i j}$ astfel încât: dacă t_i este blocat în V_j atunci nici o conexiune din $TEST$ nu va deveni internă, iar dimensiunea lui V_j rămâne mai mică decât limita de dimensiune S .
3. Se elimină t_i din T , se blochează t_i în V_j , se incrementează $S(V_j)$ cu $s(t_i)$; se actualizează valorile a_{uj} pentru fiecare $u \in T$, și se elimină din $TEST$ toate conexiunile care devin externe ca urmare a asignării t_i la V_j .
4. Dacă $TEST \neq \emptyset$, se incrementează i și se continuă cu pasul 2.

În acest moment, unele noduri sunt blocate în diferite părți pentru a asigura că toate conexiunile testabile sunt externe, în timp ce nodurile rămase neblockate nu sunt asignate nici unui subset al partiției. Se utilizează în continuare algoritmul SE pentru a termina partiționarea circuitului. Strategia generală a acestui algoritm fiind cunoscută, k_SE poate fi complet specificat prin indicarea partiției inițiale și a funcției $Perturb$.

Partiția inițială este generată utilizând aceeași euristică ca și pentru determinarea numărului de părți. În această etapă, unele subseturi ale partiției au capacități mai mici decât S datorită faptului că anumite noduri sunt deja asignate la aceste subseturi. De aceea este posibil ca algoritmul să mărească numărul de părți pentru a permite plasarea tuturor nodurilor. Se presupune însă că numărul conexiunilor testabile este redus, astfel încât cele k subseturi sunt suficiente. În euristica utilizată se presupune că sunt disponibile numai k părți, și fiecare nod neblockat va găsi un spațiu într-una din cele k părți.

Ca și în cazul algoritmului 2_SE , funcția $Perturb$ constă din doi pași: selecție și interschimbare. Pentru fiecare nod neblockat i și fiecare parte V_j se definește forma care atrage nodul i în partea V_j ca fiind:

$$F_{ij} = \begin{cases} |N_i: i \in N_i, |N_i \cap V_j| > 0\} & \text{dacă } i \notin V_j \\ |N_i: i \in N_i, |N_i \cap V_j| > 1\} & \text{dacă } i \in V_j \end{cases} \quad (3.43)$$

Pasul de selecție începe prin inițializarea a k cozi Q_1, \dots, Q_k . Nodurile neblocaate sunt scanate apoi în ordinea descrescătoare a dimensiunii. Presupunând că nodul curent scanat este i , fie

1. V_j partea curentă a nodului i .
2. V_l o parte astfel încât $l \neq j$ și F_{il} este maxim.
3. e_i = valoarea cu care scade E_j dacă nodul i este mutat în afara părții V_j .
4. g_i = valoarea cu care scade $\sum_{i=1}^n W(N_i)C(N_i)$ atunci când nodul i este mutat în partea V_l .
5. $GAIN(i) = e_i$ dacă $E_j > E_l$, $GAIN(i) = g_i$ în caz contrar.

$GAIN(i)$ este comparat cu un întreg aleator r în intervalul $[p, 0]$. Dacă $GAIN(i) > r$, nodul i dorește mutarea în V_l . În caz contrar, nodul i rămâne în V_j . Dacă nodul i se mută în V_l , atunci este eliminat din V_j , este adăugat în coada Q_l , fiind actualizate valorile F_{uj} , e_v și g_v ca și cum nodul i ar fi deja în V_l .

În pasul de interschimbare, fiecare parte acceptă numărul de noduri permis de restricția sa de dimensiune, pe baza regulii primul venit, primul servit. Nodurile rămase cărora nu li se permite intrarea în partea lor preferată sunt depuse într-o coadă L . Părțile sunt scanate apoi în ordinea crescătoare a dimensiunii. Atunci când este scanată partea V_l , aceasta permite intrarea unui număr de noduri din L în funcție de restricția sa de dimensiune. Dacă, după scanarea tuturor părților, coada L nu este vidă, nodurile rămase în L sunt returnate în părțile lor inițiale.

Calitatea soluției găsite de algoritmul k_SE depinde de alegerea parametrilor S , E și R . Dacă oricare din acești parametri are o valoare prea mică, posibilitățile de optimizare ale algoritmului sunt mult restrânse. Dacă S este prea mare, există tendința ca dimensiunile părților să fie dezechilibrate. Dacă R este prea mare, timpul de calcul crește.

3.6.2 Partiționarea prin automate de învățare

Automatele de învățare au fost utilizate pentru modelarea sistemelor biologice de învățare și de asemenea pentru procesul de învățare a acțiunii optime pe care o oferă un mediu aleator. Învățarea este realizată prin interacțiunea cu mediul și prelucrarea răspunsurilor sale la acțiunile care au fost alese.

Procesul de învățare al unui automat poate fi descris astfel: Automatului i se oferă un set de acțiuni de către mediul cu care acesta interacționează, și este constrâns să aleagă una din aceste acțiuni. Atunci când este aleasă o acțiune, automatul este fie recompensat, fie penalizat de către mediu, cu o anumită probabilitate. Automatul va învăța alegerea acțiunii optime, care este acțiunea cu probabilitatea minimă de penalizare. În final, automatul va alege această acțiune mai frecvent decât alte acțiuni.

În secțiunea 3.6.2.1 sunt prezentate pe scurt automatele stohastice de învățare, și este descrisă o categorie particulară de automate, automatul pentru migrarea obiectelor. În secțiunea 3.6.2.2 este descris un automat de învățare pentru partiționarea grafurilor.

3.6.2.1 Automate de învățare și partiționarea obiectelor

Automatele stohastice de învățare pot fi clasificate în două categorii principale:

- 1) Automate stohastice cu structură fixă
- 2) Automate a căror structură evoluează în timp

Exemple din primul tip sunt automatele Tsetlin, Krinsky și Krylov [126]. Deși automatele din al doilea tip sunt numite cu structură variabilă, deoarece matricile lor de tranziție și de ieșire sunt variabile în timp, în practică ele sunt definite în termenii regulilor de actualizare a probabilităților de acțiune.

Un automat stohastic cu structură fixă (ASSF) este un cvintuplu $(\alpha, \Phi, \beta, F, G)$, unde:

- 1) $\alpha = \{\alpha_1, \dots, \alpha_R\}$ este setul acțiunilor din care automatul trebuie să aleagă.
- 2) $\Phi = \{\phi_1, \dots, \phi_S\}$ este setul stărilor automatului.
- 3) $\beta = \{0, 1\}$ este setul intrărilor, unde "1" reprezintă o penalizare și "0" o recompensă.
- 4) $F: \Phi \times \beta \rightarrow \Phi$ este maparea de tranziție, care definește tranziția stării automatului la recepționarea unei intrări. F poate fi stohastică.
- 5) $G: \Phi \rightarrow \alpha$ este maparea de ieșire, care determină acțiunea executată de automat dacă acesta este în starea ϕ_i .

Acțiunea selectată servește ca intrare pentru mediu, care la rândul său transmite un răspuns stohastic $\beta(n)$ la momentul n . $\beta(n)$ este un element din $\beta = \{0, 1\}$ și este răspunsul de reacție al mediului pentru automat. Mediul penalizează ($\beta(n) = 1$) automatul cu penalizarea c_i , care este dependentă de acțiune. Pe baza răspunsului $\beta(n)$, starea $\phi(n)$ a automatului este actualizată și este aleasă o nouă acțiune la momentul $n+1$.

Problema de partiționare a grafurilor poate fi rezolvată în mai multe moduri, considerând această problemă ca una de căutare sau de exersare bazată pe parametri. Oommen și St. Croix [129] au propus o metodă în care problema de partiționare a grafurilor este rezolvată prin considerarea acesteia ca o problemă de partiționare a obiectelor. În acest caz, scopul este de a modela problema astfel încât să se determine nodurile din V care se potrivesc cu alte noduri cu proprietăți similare. Se încearcă deci impunerea unei măsuri inteligente de similaritate pentru noduri, astfel încât nodurile similare să se grupeze. Această măsură de similaritate este legată de apartenența sau nu a nodurilor la partiția optimă.

Există mai multe avantaje ale acestei abordări. Spre deosebire de metodele de căutare, căutarea unei soluții mai bune nu se realizează doar printr-o nouă partiționare în "vecinătatea" celei curente. Se realizează în schimb compararea unor perechi de noduri, și uneori, a unui grup de trei sau patru noduri, pentru a se asigura învățarea. De asemenea, această tehnică este adaptivă. În plus, această tehnică asigură un mecanism prin care se poate indica nodul cel mai reprezentativ pentru fiecare subpartiție. Acest nod, care poate fi considerat ca nucleul subpartiției respective, este specificat în mod automat și adaptiv de sistem. Automatul propus în [129] poate fi adaptat și pentru problema de partiționare a grafurilor în care costurile muchiilor nu sunt constante, ci sunt variabile aleatoare a căror distribuție este necunoscută.

Problema de *partiționare a obiectelor* poate fi definită astfel: Fie $A = \{A_1, \dots, A_W\}$ un set de W obiecte care trebuie partiționate în K clase $\{\pi_1, \dots, \pi_K\}$. Obiectele sunt partiționate astfel încât cele care sunt accesate împreună în mod frecvent să fie plasate în aceeași clasă. Aceasta implică existența unei partiționări corecte, numită grupare, a obiectelor. În modul cel mai simplu de partiționare a obiectelor, acestea sunt accesate în perechi $\langle A_i, A_j \rangle$, printr-o interogare. De aceea, soluția acestei probleme va prelucra o secvență de interogări astfel încât să crească probabilitatea ca perechea de obiecte accesate să facă parte din aceeași clasă la o interogare ulterioară identică.

Problema de partiționare a grafurilor este strâns legată de un caz special al partiționării obiectelor, cel în care toate clasele au aceeași dimensiune. Această problemă este numită *problema de echipartiționare*. O soluție a acestei probleme este metoda propusă de Yu. În această metodă, inițial fiecare obiect membru, A_i , este asociat cu un număr real X_i . La fiecare procesare a unei interogări $\langle A_i, A_j \rangle$, cantitățile $\{X_i, X_j\}$ sunt mutate către nucleul lor cu o anumită cantitate δ_1 . Apoi, o pereche aleatoare $\langle X_p, X_q \rangle$, ($1 \leq p, q \leq W$) este îndepărtată de nucleul acesteia cu o anumită cantitate δ_2 . Rezultatul este că obiectele similare se vor grupa împreună, iar cele nesimilare se vor separa.

O altă soluție a acestei probleme o reprezintă *automatul pentru migrarea obiectelor (AMO)*, propus de Oommen și Ma [130]. Acest automat modifică stările tuturor celor W obiecte, spre deosebire de automatul tradițional la care obiectele sunt trecute dintr-o stare în alta. Deci, atunci când acest automat este utilizat pentru rezolvarea problemei de echipartiționare, o soluție nu este definită prin starea curentă a AMO, ci prin întreaga structură a automatului. Funcția de mapare care definește tranziția automatului dintr-o stare în alta specifică mutarea a două sau trei obiecte în cadrul acestei structuri. La o interogare $\langle A_i, A_j \rangle$, dacă A_i și A_j fac parte din aceeași clasă, ambele sunt recompensate și sunt mutate cu un pas către starea cea mai interioară asociată cu acea clasă. Dacă A_i și A_j fac parte din clase diferite, ele sunt mutate cu un pas către stările care sunt învecinate cu stările din alte clase, și atunci când unul din obiecte se află într-una din aceste stări limită, va migra spre starea corespunzătoare la o altă acțiune. Rezultatele obținute cu AMO arată că acesta converge către soluția corectă în toate cazurile, într-un timp care este cu un ordin de mărime mai redus decât cel al metodei propuse de Yu.

3.6.2.2 Automat de învățare pentru partiționarea grafurilor

Automatul de învățare pentru partiționarea grafurilor (APG) are ca intrări setul de noduri $V = \{V_1, \dots, V_{2N}\}$ care trebuie partiționat în două subpartiții de dimensiuni egale, V_1 și V_2 , și setul de ponderi ale muchiilor. APG poate fi generalizat pentru cazul partiționării setului de noduri V în k subpartiții prin proiectarea acestuia astfel încât să dispună de k acțiuni. În continuare se presupune că automatul trebuie să rezolve această ultimă problemă de echipartiționare a setului V în k subseturi.

Inițial, toate obiectele (fiecare reprezentând un nod) sunt plasate aleator în cele k acțiuni. APG se definește ca un 7-tuplu astfel:

$(V, E, \{\phi_1, \phi_2, \dots, \phi_{kM}\}, \{\alpha_1, \alpha_2, \dots, \alpha_k\}, \beta, Q, G)$, unde:

- 1) $V = \{V_1, \dots, V_{kN}\}$ este setul de noduri care trebuie partiționat.
- 2) E este setul de muchii, căruia i se asociază matricea costurilor C .
- 3) $\{\phi_1, \phi_2, \dots, \phi_{kM}\}$ este setul stărilor. M se numește adâncimea memoriei automatului.
- 4) $\{\alpha_1, \alpha_2, \dots, \alpha_k\}$ este setul celor k acțiuni, fiecare reprezentând o anumită subpartiție în care trebuie plasate elementele lui V .
- 5) $\beta = \{0, 1\}$ este setul intrărilor, unde "1" reprezintă o penalizare și "0" o recompensă.
- 6) Q este funcția de tranziție, care specifică modul în care trebuie mutate obiectele între diferitele stări.
- 7) Funcția G partiționează setul stărilor. Pentru fiecare acțiune α_j există un set de stări $\{\phi_{(j-1)M+1}, \dots, \phi_{jM}\}$. Deci,

$$G(\phi_i) = \alpha_j \text{ dacă } (j-1)M + 1 \leq i \leq jM \quad (3.44)$$

Aceasta înseamnă că nodul automatului alege α_1 dacă se află în oricare din primele M stări, alege α_2 dacă se află în oricare din stările de la ϕ_{M+1} la ϕ_{2M} etc. Se presupune că $\phi_{(j-1)M+1}$ este starea cea mai interioară a acțiunii α_j , iar ϕ_{jM} este starea de graniță. Acestea reprezintă starea de *Certitudine_Maximă*, respectiv de *Certitudine_Minimă*.

Dacă stările ocupate de noduri sunt date, subpartițiile se pot obține din relația (3.44). Aceasta va specifica complet setul subpartițiilor dictate în mod curent de APG. Fie $\omega_i(n)$ indexul stării ocupate de nodul v_i la momentul de timp n . Pe baza acestui index și a relației (3.44) APG va decide o partiționare curentă a setului V în subpartiții.

În timpul procesului de învățare scopul este de a se colecta noduri similare ale grafului în aceeași subpartiție. Principiul utilizat pentru cuantificarea acestei similarități este analog cu cel utilizat de Kernighan și Lin. Se consideră că două noduri sunt similare dacă ele sunt puternic conectate, și deci costul muchiei acestora este redus. Explicit, se consideră că nodurile sunt puternic conectate dacă muchia corespunzătoare lor are un cost care este de $(1 + \rho)$ ori costul mediu al muchiilor pentru întregul graf, unde ρ este un parametru specificat de utilizator. Similar, nodurile sunt slab conectate dacă muchia lor are un cost care este de $(1 - \rho)$ ori costul mediu al muchiilor [129].

Diferitele stări din cadrul unei subpartiții date cuantifică măsura de certitudine pe care o are sistemul pentru un nod dat aparținând subpartiției respective. La început toate nodurile sunt plasate în subpartiții alese în mod aleator, în starea limită (de *Certitudine_Minimă*) a acestor subpartiții, indicând faptul că sistemul este nesigur de plasarea corectă a nodurilor. Pe măsura procesului de învățare, nodurile similare ale grafului vor fi recompensate pentru apartenența lor la aceeași subpartiție, și vor migra către starea cea mai interioară a subpartiției (de *Certitudine_Maximă*), indicând faptul că sistemul este mai sigur de plasarea nodurilor în subpartițiile corecte. În același timp, alte noduri vor fi penalizate și vor fi mutate fie spre starea lor limită, fie în altă subpartiție, indicând ambiguitatea sistemului în privința asocierii lor cu subpartiția curentă.

Inițial, automatul are o fază de preprocesare în care se evaluează costul mediu al muchiilor. Urmează apoi bucla principală de învățare a algoritmului. Muchiile sunt procesate în mod repetat, într-o ordine aleatoare. La procesarea unei muchii e_{ij} , dacă v_i și v_j sunt similare și aparțin aceleiași subpartiții, nodurile v_i și v_j sunt recompensate. Acest mod de recompensare se numește *Recompensare_Noduri_Similare*. Dacă ele sunt asignate însă unor subpartiții diferite, automatul este penalizat. Acest mod de penalizare se numește *Penalizare_Noduri_Similare*.

Dacă v_i și v_j sunt nesimilare și aparțin unor subpartiții diferite, automatul (și, în particular, nodurile v_i și v_j) sunt recompensate. Acest mod de recompensare se numește *Recompensare_Noduri_Nesimilare*. Dacă însă nodurile sunt asignate aceleiași subpartiții, automatul este penalizat. Prin analogie cu cele de sus, acest mod de penalizare se numește *Penalizare_Noduri_Nesimilare*.

Ciclul continuă apoi cu următoarea iterație, unde fazele de recompensare și penalizare se repetă.

Se prezintă în continuare tranzițiile descrise de funcția Q pentru fiecare din aceste operații.

Modul *Recompensare_Noduri_Similare*. Acesta este cazul întâlnit atunci când nodurile v_i și v_j sunt considerate similare și se află simultan în aceeași subpartiție, de exemplu α_k . Din acest motiv, ambele noduri sunt mutate către starea cea mai interioară a acelei subpartiții, $\phi_{(k-1)M+1}$, cu câte un pas în fiecare moment de timp (Figura 3.26). Dacă oricare din noduri se află în starea cea mai interioară, va rămâne în această stare.




Figura 3.26. Tranziții de recompensare pentru APG cu 2M stări. În acest caz (modul *Recompensare_Noduri_Similare*), v_i și v_j sunt similare și se află în aceeași subpartiție.

Modul *Recompensare_Noduri_Nesimilare*. În acest caz nodurile v_i și v_j sunt considerate nesimilare și se află în subpartiții diferite, de exemplu α_k , respectiv α_m . Ambele noduri sunt mutate către starea cea mai interioară a subpartiției respective, $\phi_{(k-1)M+1}$ și $\phi_{(m-1)M+1}$, cu câte un pas în fiecare moment de timp.

Modul *Penalizare_Noduri_Similare*. Acesta este cazul întâlnit atunci când două noduri similare, v_i și v_j , sunt plasate în subpartiții diferite, de exemplu α_k , respectiv α_m . Nodul v_i se află în starea ω_i , unde $\omega_i \in \{\phi_{(k-1)M+1}, \dots, \phi_{kM}\}$, iar nodul v_j se află în starea ω_j , unde $\omega_j \in \{\phi_{(m-1)M+1}, \dots, \phi_{mM}\}$. Din acest motiv, nodurile sunt mutate din stările ω_i și ω_j , după cum urmează:

- 1) Dacă $\omega_i \neq \phi_{kM}$ și $\omega_j \neq \phi_{mM}$, se mută v_i și v_j cu o stare către ϕ_{kM} , respectiv ϕ_{mM} . Astfel, nodurile se mută către stările limită ale subpartițiilor respective (Figura 3.27).




Figura 3.27. Tranziții de penalizare pentru APG cu 2M stări – modul *Penalizare_Noduri_Similare*: v_i și v_j sunt similare, dar se află în subpartiții distincte.

- 2) Dacă cel puțin unul din nodurile v_i și v_j se află în starea limită (deci, $\omega_i = \phi_{kM}$ sau $\omega_j = \phi_{mM}$), atunci se mută nodul din starea limită a subpartiției sale în starea limită a subpartiției celuilalt nod. De exemplu, dacă nodul v_j se află în starea limită, v_j se mută în starea ϕ_{kM} , care este starea limită a subpartiției α_k . În acest caz, deoarece va rezulta un exces de noduri în partiția α_k , unul din nodurile diferite de v_i din α_k este mutat în starea ϕ_{mM} , care este starea limită din α_j . Se alege mutarea nodului cel mai apropiat de ϕ_{kM} (Figura 3.28).

Modul *Penalizare_Noduri_Nesimilare*. Acesta este cazul întâlnit atunci când două noduri nesimilare, v_i și v_j , sunt plasate în aceeași subpartiție, de exemplu α_k . Din acest motiv, ambele noduri sunt mutate din starea ω_i , după cum urmează:




Figura 3.28. Tranziții de penalizare pentru APG cu $2M$ stări – modul *Penalizare_Noduri_Similare*. În acest caz v_i și v_j sunt similare, dar se află în subpartii distincte. Unul din noduri (v_j) se află într-o stare limită.

- 1) Dacă $\omega_i \neq \phi_{kM}$ și $\omega_j \neq \phi_{mM}$, se mută v_i și v_j cu o stare către starea limită ϕ_{kM} (Figura 3.29).




Figura 3.29. Tranziții de penalizare pentru APG cu $2M$ stări – modul *Penalizare_Noduri_Nesimilare*. În acest caz v_i și v_j sunt nesimilare, dar se află în aceeași subpartie. Niciunul din noduri nu se află într-o stare limită.

- 2) Dacă cel puțin unul din nodurile v_i și v_j se află în starea limită (deci, $\omega_i = \phi_{kM}$ sau $\omega_j = \phi_{kM}$), atunci se mută nodul aflat în starea limită, de exemplu v_j , în starea ϕ_{2M} , care este starea limită a subpartiei α_2 . În cazul bipartiționării, aceasta este întotdeauna subpartia diferită de cea în care se află nodul. În cazul multipartitiționării, modul migrat este mutat în mod repetat în toate cele $k-1$ subpartii, și în final este reținut în cea mai bună dintre ele. Aceasta este cea care minimizează costurile dintre seturi. Și în acest caz, deoarece va rezulta un exces de noduri în partea α_2 , unul din nodurile din α_2 , cel mai apropiat de ϕ_{2M} , este mutat în starea ϕ_{mM} (Figura 3.30).




Figura 3.30. Tranziții de penalizare pentru APG cu $2M$ stări – modul *Penalizare_Noduri_Nesimilare*. În acest caz v_i și v_j sunt nesimilare, dar se află în aceeași subpartie. Unul din noduri (v_j) se află într-o stare limită.

Algoritmul automatului pentru multipartiționarea grafurilor este prezentat în Figura 3.31.

Deși principiile fundamentale ale migrării nodurilor sunt bazate pe filozofia utilizată de automatul pentru migrarea obiectelor *AMO*, algoritmul este diferit [129]. Spre deosebire de *AMO*, unde migrațiile se efectuează atunci când utilizatorul execută o cerere, în cazul *APG* migrațiile se execută pentru toate perechile de noduri procesate. De asemenea, *APG* are o strategie de penalizare a elementelor neaccesate prin considerarea gradului de similaritate a nodurilor din aceeași subpartiție. *APG* permite cuantificarea gradului de potrivire a unui nod pentru o anumită subpartiție. Nodul cel mai apropiat de starea cea mai interioară poate fi considerat ca fiind nodul care reprezintă cel mai bine acea subpartiție.

Deși *APG* obține soluții într-un timp redus, acestea nu reprezintă de obicei optimul global. Cu alte cuvinte, *APG* determină într-un timp scurt regiunea apropiată de o soluție optimă. Aceasta din cauza nodurilor care au tendința să migreze între diferitele subpartiții, și deci au tendința de a rămâne în stările limită ale acestor subpartiții. De aceea, se obține o îmbunătățire dacă algoritmul este urmat de o singură iterație a unui algoritm de căutare locală de tip Kernighan-Lin.

```

Algorithm APG;
  /* Intrarea este setul  $V = \{v_1, \dots, v_{kN}\}$  care trebuie partiționat în  $k$  subpartiții. */
  /* Ieșirile sunt subpartițiile  $\{V_1, V_2, \dots, V_k\}$ . */
  /*  $C$  este matricea de adiacență a costurilor. */
  /*  $\rho$  este un parametru utilizat pentru a decide similaritatea nodurilor. */
begin
  Se calculează costul mediu pe muchie Cost_Mediu;
  Se echipartiționează  $V$  în mod aleator în  $\{V_1, V_2, \dots, V_k\}$ ;
  Se asignează nodurilor stările limită ale sub-partițiilor;
  for (Iter = 1 to Max_Iter) do
    for (o muchie aleatoare  $e_{ij}$ ) do
      if ( $C_{ij} > (1+\rho) \cdot \text{Cost\_Mediu}$ ) then
        if ( $v_i$  și  $v_j$  sunt în aceeași clasă) then
          Recompensare_Noduri_Similare ( $i, j$ );
        else
          Penalizare_Noduri_Similare ( $i, j$ );
        endif
      else
        if ( $C_{ij} < (1-\rho) \cdot \text{Cost\_Mediu}$ ) then
          if ( $v_i$  și  $v_j$  sunt în aceeași clasă) then
            Penalizare_Noduri_Nesimilare ( $i, j$ );
          else
            Recompensare_Noduri_Nesimilare ( $i, j$ );
          endif
        endif
      endif
    endif
  endfor
endfor
end.

```

Figura 3.31. Algoritmul automatului de învățare pentru partiționarea grafurilor.

3.7 Algoritmi de partiționare propuși pentru circuite FPGA cu resurse limitate de rutare

Circuitele FPGA utilizează comutatoare programabile care permit configurarea acestora de către utilizator. Acest avantaj se obține cu costul unui grad de utilizare mai redus al porțiilor disponibile. Unul din motivele reducerii gradului de utilizare al porțiilor este disponibilitatea limitată a resurselor de rutare în circuitele FPGA comerciale: existența unui număr fix de piste într-un canal de rutare și limitări ale interconexiunilor disponibile între piste. În special în cazul circuitelor FPGA cu resurse limitate de rutare, cum sunt și circuitele FPGA *Atmel*, este foarte importantă utilizarea unor tehnici care să asigure rutabilitatea circuitelor.

Pentru asigurarea rutabilității circuitelor, trebuie realizată o plasare corespunzătoare a celulelor. În cazul utilizării unor algoritmi de plasare bazați pe partiționare, algoritmul de partiționare trebuie să aibă în vedere acest obiectiv al rutabilității. Cei mai utilizați algoritmi de partiționare se bazează pe metoda tăieturii minime, cu scopul de a minimiza numărul interconexiunilor intersectate de o serie de linii de tăietură. Plasarea care utilizează această partiționare are rolul de a grupa cât mai mult celulele interconectate, lungimea totală a interconexiunilor fiind componenta principală a funcției de cost utilizate de algoritmi tradiționali de plasare.

Lungimea totală a interconexiunilor nu este însă o metrică adecvată pentru circuitele FPGA cu resurse limitate de rutare. Deoarece algoritmul va încerca plasarea apropiată a celulelor conectate, este posibil ca plasarea rezultată să fie dificil sau imposibil de rutat. În această secțiune se vor prezenta algoritmi de partiționare care au ca obiectiv echilibrarea numărului de conexiuni din cadrul partițiilor, minimizând în același timp lungimea totală a interconexiunilor. În secțiunea 3.7.1 se va prezenta un algoritm de partiționare bazat pe metoda tăieturii minime. În secțiunea 3.7.2 se va prezenta un algoritm genetic pentru partiționare, cu un obiectiv similar cu cel al algoritmului bazat pe tăietura minimă.

3.7.1 Algoritm de partiționare cu echilibrarea numărului de conexiuni

Pentru a elabora o procedură eficientă de partiționare, este necesară o metrică pentru a măsura congestia canalelor de rutare. Un indicator al acestei congestii este dimensiunea tăieturii, deci numărul de conexiuni intersectate de o linie de tăietură din circuit. Într-un circuit FPGA cu $a \times b$ celule logice, există $a - 1$ linii de tăietură orizontale și $b - 1$ linii de tăietură verticale. Fiecărui canal de rutare îi corespunde o linie de tăietură. Dimensiunea tăieturii unei linii de tăietură este definită prin numărul de conexiuni care au terminale de ambele părți ale liniei de tăietură. Această dimensiune reprezintă o limită inferioară a numărului de piste necesare pentru rutarea completă a circuitului. Deci, dacă dimensiunea tăieturii unei linii de tăietură orizontale (verticale) este mai mare decât numărul pistelor verticale (orizontale), rutarea completă nu este posibilă.

O linie de tăietură care trece printr-o zonă cu un număr mare de conexiuni are de obicei o dimensiune mare a tăieturii. Dacă dimensiunea maximă a tăieturii, deci dimensiunea care este cea mai mare dintre toate liniile de tăietură orizontale și verticale, scade, posibilitatea existenței unor zone congestionate din punct de vedere al conexiunilor scade în mod corespunzător. De aceea, este de dorit minimizarea dimensiunii maxime a tăieturii. Suma dimensiunii tăieturilor pentru toate liniile de tăietură orizontale și verticale indică lungimea totală a conexiunilor atunci când această lungime pentru o conexiune cu terminale multiple este estimată prin metoda semi-perimetrului.

Algoritmii de plasare bazează pe partiționarea de tip Kernighan-Lin execută în mod recursiv bipartiționarea grafului (sau hiper-grafului) care reprezintă circuitul, până când graful este suficient de simplu (de exemplu, un graf cu un singur nod) pentru a fi plasat într-o celulă a circuitului. Obiectivul fiecărei bipartiționări este de a minimiza dimensiunea tăieturii cu restricția ca dimensiunile (numărul de noduri) celor două partiții obținute să fie aproximativ egale. În cazul acestor algoritmi, singura metrică în cadrul funcției de cost minimizate este dimensiunea tăieturii. De aceea, se poate obține o partiție cu o dimensiune redusă a tăieturii, în care una din porțiuni conține un număr mare de conexiuni, în timp ce numărul conexiunilor din a doua porțiune este redus. Se propune un algoritm de bipartiționare care ține cont nu numai de dimensiunile celor două porțiuni, ci și de distribuția interconexiunilor din cadrul celor două porțiuni.

Conexiunile cu terminale multiple se consideră reprezentate printr-un hipergraf. În general, pentru a conecta k terminale, sunt necesare $\max\{k-1, 0\}$ căi de conectare. Se definește *dezechilibrul* unei conexiuni ca fiind diferența dintre numărul căilor de interconectare necesare pentru conectarea terminalelor din porțiunea din stânga și numărul căilor de interconectare necesare pentru conectarea terminalelor din porțiunea din dreapta. Dezechilibrul unei bipartiții este definit ca suma valorilor de dezechilibru pentru toate conexiunile. Valoarea absolută a dezechilibrului unei bipartiții indică diferența dintre numărul căilor de conectare necesare în porțiunea din stânga și același număr din porțiunea din dreapta.

Fiind dată o bipartiție inițială, se poate calcula dezechilibrul acesteia într-un timp de $O(|T|)$ prin examinarea tuturor conexiunilor, unde T este setul tuturor terminalelor. Fără restrângerea generalității, presupunem că există un număr mai mare de căi de interconectare în porțiunea din stânga decât în cea din dreapta, deci dezechilibrul unei bipartiții este pozitiv. Dacă un nod v este mutat din porțiune din stânga în cea din dreapta, se poate calcula funcția $f(v, e)$, reprezentând cantitatea cu care scade dezechilibrul unei conexiuni e , prin examinarea setului tuturor vecinilor lui v , $N(v)$. Câștigul care indică reducerea dezechilibrului este definit prin

$$F(v) = \sum_{\forall v \in e} f(v, e) \quad (3.45)$$

Dacă nodul v este mutat dintr-o porțiune în cealaltă, este necesar un timp de $O(|N(v)|)$ pentru actualizarea valorii funcțiilor de câștig. Atunci când un nod v dintr-o porțiune este interschimbabil cu un alt nod u din cealaltă porțiune, în cazul în care nu există o muchie care conectează cele două noduri, reducerea dezechilibrului bipartiției este suma dintre $F(v)$ și $F(u)$. În cazul în care există muchii între cele două noduri, pentru fiecare asemenea muchie, e , se scade valoarea $f(u, e) + f(v, e)$ din suma $F(v) + F(u)$.

Se utilizează următoarea funcție de cost pentru a ține cont de distribuția numărului de conexiuni în cadrul unei partiții:

$$Cost = Dim_tăietură + PONDERE \times Dezechilibru \quad (3.46)$$

unde *PONDERE* este o constantă. Dacă această constantă este setată la zero, algoritmul este același cu cel convențional. Prin setarea corespunzătoare a ponderii se poate controla importanța echilibrării numărului de conexiuni.

Se consideră un graf $G = (V, E)$ cu $2n$ vârfuri. Algoritmul de bipartiționare cu echilibrarea numărului de conexiuni este prezentat în Figura 3.32 [14].

Tabloul *Blocat* memorează valoarea 0 dacă un nod este disponibil pentru interschimbare și 1 dacă nodul este blocat. Procedura *PART_INIT* (G, n) selectează un subgraf de dimensiune n . E_i și I_i reprezintă costul extern, respectiv costul intern al nodului i (3.4.1). Procedura *INTERSCH* (V_1, V_2, v_i, v_j) interschimbă nodurile $v_i \in V_1$ și $v_j \in V_2$ din două subgrafuri G_1 , respectiv G_2 . Tabloul *gain* memorează câștigul pentru fiecare pereche de noduri, iar tablourile *max1* și *max2* păstrează indicii acestor

noduri. Tabloul *GAIN* memorează câștigul acumulat pentru o secvență de n inter-schimbări. Variabilele *bestk* și *bestGAIN* conțin indexul, respectiv valoarea câștigului maxim acumulat.

```

Algorithm Partit_echil ( $G, n, PONDERE$ );
begin
   $G_1 = PART\_INIT(G, n)$ ;
   $G_2 = G - G_1$ ;
   $bestGAIN = \infty$ ;
  while  $bestGAIN > 0$  do
     $nr\_dezechilibru = DEZECHILIBRU(n)$ ;
     $bestGAIN = 0$ ;  $bestk = 0$ ;
    for  $i = 1$  to  $2n$  do  $Blocat(i) = 0$ ; endfor;
    for  $k = 1$  to  $n$  do
       $gain(k) = 0$ ;  $GAIN(k) = 0$ ;
      /* Se caută nodurile care vor fi interschimbate */
      for all  $v_i \in G_1$  AND  $Blocat(i) = 0$  do
        for all  $v_j \in G_2$  AND  $Blocat(j) = 0$  do
           $gain\_cut = D_i + D_j - 2 c_{ij}$ ;
           $nr\_dezechilibru\_nou = nr\_dezechilibru - E_i - I_i + E_j + I_j$ ;
           $gain\_dez = |nr\_dezechilibru - nr\_dezechilibru\_nou|$ ;
          if  $(gain\_cut + PONDERE * gain\_dez) > gain(k)$  then
             $gain(k) = gain\_cut + PONDERE * gain\_dez$ ;
             $max1(k) = i$ ;  $max2(k) = j$ ;
          endif;
        endfor;
      endfor;
       $Blocat(max1(k)) = Blocat(max2(k)) = 1$ ;
      /* Actualizează câștigul după tentativa de interschimbare */
      for  $i = 1$  to  $2n$  do
        if  $v_i \in G_1$  AND  $Blocat(i) = 0$  then
           $D_i = D_i - c_{i,max2(k)} + c_{i,max1(k)}$ 
        endif;
        if  $v_i \in G_2$  AND  $Blocat(i) = 0$  then
           $D_i = D_i - c_{i,max1(k)} + c_{i,max2(k)}$ 
        endif;
      endfor;
      /* Calculează câștigul acumulat */
       $GAIN(k) = GAIN(k-1) + gain(k)$ ;
      if  $GAIN(k) > bestGAIN$  then
         $bestk = k$ ;  $bestGAIN = GAIN(k)$ ;
      endif;
    endfor;
    /* Interschimbă k perechi de noduri */
    for  $k = 1$  to  $bestk$  do
       $(G_1, G_2) = INTERSCH(V_1, V_2, v_{max1(k)}, v_{max2(k)})$ ;
    endfor;
  endwhile;
end.

```

Figura 3.32. Algoritm de bipartiționare cu echilibrarea numărului de conexiuni.

3.7.2 Algoritm genetic pentru partiționare cu echilibrarea numărului de conexiuni

Algoritmii genetici reprezintă o tehnică de căutare în cadrul unui spațiu al soluțiilor, care emulează procesul natural al evoluției ca o modalitate de evoluare către o soluție optimă [146]. Acești algoritmi au fost aplicați pentru rezolvarea diferitelor probleme de optimizare, inclusiv pentru bipartiționarea sau multipartiționarea grafurilor.

3.7.2.1 Terminologia algoritmilor genetici

O soluție a unei probleme de optimizare este reprezentată de un *cromozom*. Pentru problemele cu grafuri, dimensiunea unui cromozom este egală adesea cu numărul de vârfuri ale grafului. Un cromozom este format dintr-un șir de simboluri numite *gene*. Fiecare genă are o valoare dintr-un alfabet S . De exemplu, în cazul problemei de bisecție a grafurilor, fiecare vârf al grafului este reprezentat printr-o genă dintr-un cromozom. Fiecare genă reprezentând un vârf va ocupa aceeași poziție în fiecare cromozom.

Un subset de gene aflate în anumite poziții, și care formează o soluție parțială a problemei, se numește *schemă*. Într-un mod mai formal, dacă n este dimensiunea cromozomului, o schemă este un n -tuplu $\langle s_1, s_2, \dots, s_n \rangle$, unde $s_i \in S \cup \{*\}$ pentru $i = 1, 2, \dots, n$. Într-o schemă, simbolul $*$ reprezintă poziții indiferente, iar celelalte simboluri (numite *simboluri specifice*) indică pozițiile definiției ale subsetului și valorile corespunzătoare ale genelor. Numărul simbolurilor specifice dintr-o schemă este numit *ordin* al schemei. Lungimea dintre simbolul specific cel mai din stânga și simbolul specific cel mai din dreapta este numită *lungimea definiției* a schemei.

Considerând o codificare binară de lungime 3, 101 și 001 sunt exemple de cromozomi, iar 10* este o schemă reprezentând setul cromozomilor având valoarea 1 în prima poziție și 0 în poziția a doua. Aceasta este o schemă de ordin 2 și lungime definiției 1. Un cromozom de lungime n poate fi considerat ca o instanțiere a 2^n scheme. De exemplu, cromozomul 101 este o instanțiere a $2^3 = 8$ scheme: ***, 1**, *0*, **1, 10*, 1*1, *01 și 101.

3.7.2.2 Principiul algoritmilor genetici

Un algoritm genetic pornește de la un set de soluții inițiale (cromozomi), care reprezintă o *populație*. Această populație evoluează apoi la alte populații diferite pe durata mai multor iterații (*generații*). În timpul fiecărei iterații indivizii din populația curentă sunt evaluați utilizând o anumită măsură de viabilitate. Pe baza acestei evaluări, sunt selectați doi membri ai populației (numiți *părinți*). Asupra părinților selectați se aplică apoi un număr de operatori genetici pentru a genera noi soluții numite *urmași*. Acest proces este cunoscut ca *reproducție*, indivizii care sunt mai viabili având o probabilitate mai mare de reproducție. Viabilitatea este legată de funcția de cost, iar în cazul unei probleme de minimizare a unei funcții, viabilitatea este de obicei inversul funcției de cost.

Operatorii genetici combină caracteristicile ambilor părinți. Operatorii genetici cei mai utilizați sunt *încrucșarea* (*crossover*), *mutația* și *inversiunea*. Aceștia sunt derivați prin analogie cu procesul biologic al evoluției.

Încrucșarea este principalul operator genetic. Reprezintă un mecanism ereditar prin care un urmaș moștenește unele caracteristici ale părinților. Operația de încrucșare constă din alegerea unui punct de tăietură arbitrar și generarea urmașului prin combinarea segmentului din stânga punctului de tăietură al unui părinte cu segmentul din dreapta punctului de tăietură al celuilalt părinte. Se selectează deci o anumită

schemă dintr-un părinte și o altă schemă din celălalt părinte. Operația de încrucișare crează de asemenea noi scheme care nu sunt prezente în cadrul părinților.

Mutația produce modificări aleatoare într-un singur individ. Urmașul generat prin încrucișare este modificat cu un operator de mutație pentru a introduce un spațiu de căutare neexplorat pentru populație, crescând diversitatea acestei populații (gradul de diferență între cromozomii din populație). Mutația este similară cu interschimbarea perechilor din algoritmi convenționali de partiționare. Are rolul de a evita minimele locale și împiedică înlocuirea tuturor indivizilor din populație cu copii multiple ale unui singur individ.

Inversiunea este un operator care modifică reprezentarea unui individ fără modificarea efectivă a individului, astfel încât urmașul va moșteni cu o probabilitate mai mare anumite scheme de la un părinte. Inversiunea modifică lungimea efectivă a unei scheme fără a schimba măsura de viabilitate a individului, în scopul creșterii probabilității de supraviețuire a schemelor mai lungi.

După aplicarea operatorilor genetici, noii urmași sunt evaluați pentru a testa dacă sunt corespunzători pentru populație. Se execută apoi un proces de *înlocuire*. Pentru aceasta se selectează în mod probabilistic indivizi din vechea populație și din cadrul urmașilor, pe baza viabilității lor relative. Se dispune acum de o nouă populație, terminându-se un ciclu de reproducție-evaluare pentru o generație sau iterație a algoritmului genetic. Procesul de evoluție este repetat până când este satisfăcută o anumită condiție, de exemplu pentru un anumit număr de generații.

Există algoritmi genetici care generează un singur urmaș în fiecare generație. Un asemenea algoritm se numește *cu stări stabile*, spre deosebire de un algoritm *generațional*, care înlocuiește întreaga populație sau un subset de dimensiuni mari al populației în fiecare generație. O structură tipică a unui algoritm genetic cu stări stabile este prezentată în Figura 3.33. Dacă se adaugă o euristică de îmbunătățire locală, de obicei după mutație, se obține un algoritm genetic *hibrid*.

```

Algorithm Genetic;
begin
    Se crează populația inițială de dimensiune fixată;
    repeat
        Se alege părinte1 și părinte2 din populație;
        urmaș = crossover (părinte1, părinte2);
        mutation (urmaș);
        if viabil (urmaș) then
            replace (populație, urmaș);
        endif
    until (condiție de terminare)
end.

```

Figura 3.33. Structura tipică a unui algoritm genetic cu stări stabile.

După cum s-a menționat în secțiunea 3.7.2.1, un cromozom este o instanțiere a 2^n scheme. O operație explicită asupra cromozomului poate fi considerată și ca o operație implicită asupra celor 2^n scheme. Deci, un algoritm genetic lucrează în mod explicit cu cromozomi, și în mod implicit cu un număr exponențial de scheme. Aceasta reprezintă un *parallelism implicit* sau *parallelism intrinsec* [31].

O teoremă importantă a algoritmilor genetici este numită teorema schemelor. Această teoremă specifică faptul că numărul instanțelor unei scheme într-o populație dată crește de la o generație la alta într-o măsură proporțională cu viabilitatea sa relativă față de o altă schemă din populația prezentă.

Într-un mod mai formal, fie $P(t)$ populația la momentul t . Se notează cu $m(H, t)$ numărul așteptat de cromozomi din populația $P(t)$ conținând o schemă H . O limită a

numărului așteptat de cromozomi din populația $P(t + 1)$ conținând schema H este dată de Teorema 3.7.2.2.

Teorema 3.7.2.2 [31]. Într-un algoritm genetic care utilizează o selecție proporțională și o încrucișare cu un singur punct, este adevărată următoarea inegalitate pentru fiecare schemă H reprezentată în $P(t)$:

$$m(H, t + 1) \geq m(H, t) \frac{f(H, t)}{f'(t)} \left[1 - P_c \frac{\delta H}{n - 1} \right] \quad (3.47)$$

unde $f(H, t)$ este valoarea de viabilitate medie a cromozomilor conținând schema H la momentul t , $f'(t)$ este valoarea de viabilitate medie a tuturor cromozomilor din $P(t)$ la momentul t , P_c este rata de încrucișare, $\delta(H)$ este lungimea definitorie a schemei H , iar n este lungimea fiecărui cromozom.

Datorită importanței sale, această teoremă este numită și *Teorema fundamentală a algoritmilor genetici* [83]. Inegalitatea (3.47) arată că schemele de calitate mai ridicată au șanse mai mari de supraviețuire pe măsura trecerii generațiilor.

Demonstrarea convergenței algoritmilor genetici este dificilă, deoarece într-o singură operație de încrucișare sunt create și distruse un număr mare de scheme, iar viabilitatea unei scheme date relativ la restul populației se modifică în fiecare generație pe măsură ce populația se schimbă [124]. De exemplu, algoritmul genetic poate fi modelat ca un proces Markov. Fiecare stare din lanțul Markov corespunde unei anumite populații de indivizi. Atunci când dimensiunea populației și parametrii genetici (ratele de încrucișare și mutație) sunt constante, se obține un lanț Markov omogen în timp, cu o distribuție finală staționară a probabilităților stărilor. Aceasta nu garantează însă că soluția optimă globală va fi găsită.

O altă problemă a algoritmilor genetici este alegerea valorilor optime pentru dimensiunea populației, rata de încrucișare, rata de mutație, rata de inversiune, și a altor parametri. Rezultatele teoretice obținute de cercetători în acest sens sunt valabile pentru clase restrânse de probleme. Cu anumite criterii restrictive de convergență, s-a arătat că dimensiunea optimă a populației este 3 [124]. Însă, cu criterii mai puțin restrictive de convergență, dimensiunea optimă a populației este legată de lungimea n a reprezentării genetice a unui individ. Pentru un șir de lungime 50, dimensiunea optimă a populației este apropiată de 2000; pentru un șir de lungime 60, această dimensiune este de peste 8000.

3.7.2.3 Algoritm genetic de partiționare cu echilibrarea numărului de conexiuni

Fie un graf $G = (V, E)$ caracterizat printr-un set de n noduri V și un set de e muchii E . Algoritmul genetic pentru partiționare poate fi descris pe scurt astfel. Se pornește de la o populație inițială de partiții. În fiecare generație, se obțin partiții următoarele printr-un proces de încrucișare între două partiții părinte, cu o rată specifică de încrucișare. Se utilizează de asemenea un proces de mutație pentru a schimba compoziția structurală a unui număr redus de partiții din populație. Din partițiile inițiale și din cele generate prin încrucișare este selectat un set de partiții care va constitui populația generației următoare. Acest proces este continuat pe parcursul mai multor generații. În final, partiția cea mai bună din cadrul populației este aleasă ca soluție a problemei de partiționare.

Procesul de evoluție genetică modifică structura elementelor din cadrul populației. De aceea reprezentarea structurală a soluției este foarte importantă. Structura conține blocuri constructive numite gene. O soluție parțială este reprezentată de o schemă. Populația de soluții poate fi considerată ca o reprezentare colectivă a unui mare număr de scheme. Pe parcursul evoluției, populația se îmbogățește cu scheme mai viabile. Viabilitatea unei soluții se reflectă în costul funcției obiectiv care se asociază cu soluția respectivă.

Fiecare soluție a problemei este reprezentată printr-un cromozom, care este un șir binar. Un cromozom corespunde deci unei biseccii a grafului. Numărul de gene ale unui cromozom este egal cu n , numărul de vârfuri ale grafului. O genă are valoarea 0 dacă vârful corespunzător se află în partea stângă a bisecciei, și are valoarea 1 dacă vârful se află în partea dreaptă a bisecciei.

Pentru *inițializare*, algoritmul crează în mod aleator N_p soluții, unde N_p este dimensiunea populației. De obicei, o populație de dimensiune mai mare implică o soluție finală de calitate mai bună, dar și un timp de execuție mai mare. Presupunând că numărul de vârfuri ale grafului este par, singura restricție asupra unui cromozom este că acesta trebuie să conțină un număr egal de valori 0 și 1.

Fiecărei soluții din cadrul populației i se asignează o valoare de viabilitate calculată din dimensiunea tăieturii. Valoarea viabilității F_i a soluției i se calculează astfel:

$$F_i = 1 / (Dim_tăietură + PONDERE \times Dezechilibru) \quad (3.48)$$

unde *Dim_tăietură* este dimensiunea tăieturii soluției, *PONDERE* este o constantă, iar *Dezechilibru* este diferența între numărul de conexiuni din porțiunea din stânga a partiției și numărul de conexiuni din porțiunea din dreapta a partiției. Un cromozom este selectat ca un părinte cu o probabilitate care este proporțională cu valoarea sa de viabilitate. Aceasta este o metodă obișnuită de selecție a părinților, numită *selecție proporțională*.

Un *operator de încrucișare* crează un nou cromozom urmaș prin combinarea unor părinți ale celor doi cromozomi părinte. Cel mai simplu operator de încrucișare selectează în mod aleator un punct de tăietură, care este același pentru ambii cromozomi părinte. Acest punct divide cromozomul în două părți, partea stângă și partea dreaptă. Partea stângă a părintelui 1 și partea dreaptă a părintelui 2 sunt copiate în aceleași poziții ale cromozomului urmaș. Fie acesta urmașul 1.

Algoritmul propus utilizează și un alt operator de încrucișare, care este același cu cel descris, cu excepția faptului că se copiază valorile complementare ale părții drepte a părintelui 2, în timp ce partea stângă a părintelui 1 este copiată nemodificat. Fie acesta urmașul 2. Algoritmul selectează cel mai bun dintre cei doi urmași. Motivul pentru utilizarea a doi operatori de încrucișare este următorul. Dacă doi cromozomi sunt exact (sau aproape exact) complementul unuia față de celălalt, aceștia reprezintă aceeași (sau aproape aceeași) biseccie. În acest caz, primul operator va crea o inconsistență într-un cromozom urmaș, și în consecință acest cromozom va avea o calitate redusă.

Operatorul de mutație utilizat funcționează astfel: sunt selectate în mod aleator m poziții în cadrul cromozomului, și valorile lor sunt inversate. Valoarea lui m este un întreg în intervalul $[0, n/10]$. După operațiile de încrucișare și mutație, un urmaș poate avea un număr diferit de valori 0 și 1. Algoritmul calculează diferența dintre numărul valorilor de 1 și 0. Apoi selectează un punct aleator din cromozom și modifică numărul necesar de valori de 1 în 0 (sau 0 în 1) începând din acel punct spre dreapta (continuând de la stânga dacă este necesar). Această ajustare produce de asemenea un efect de mutație.

După generarea unui nou urmaș, algoritmul înlocuiește un membru al populației cu acest urmaș. Calitatea soluțiilor depinde în mare măsură de *metoda de înlocuire*. Trebuie aleasă o metodă de înlocuire care generează soluții de calitate într-un timp rezonabil.

În literatură au fost propuse diferite metode de înlocuire. Whitley și Kauth au sugerat, în cadrul sistemului *Genitor*, o metodă în care un urmaș înlocuiește membrul cel mai inferior calitativ al populației. Cu această metodă, algoritmul poate converge rapid, dar diversitatea populației se poate reduce în mod semnificativ în primele generații. De aceea, calitatea soluțiilor poate fi necorespunzătoare.

Cavichio a propus o metodă numită *preselecție*, în care un urmaș înlocuiește părintele numai dacă acesta este inferior calitativ, cu scopul de a menține diversitatea

populației. Această metodă conduce de obicei la rezultate mai bune decât înlocuirea de tip *Genitor*, deoarece poate menține o mai mare diversitate a populației. Totuși, această diversitate poate fi relativ redusă, mai ales dacă părintele superior calitativ este similar cu urmașul. Deoarece soluțiilor cu valori mari de viabilitate li se atribuie probabilități de selecție mai mari, această metodă supraestimează soluțiile bune. Astfel, anumite scheme de calitate din soluțiile inferioare vor fi pierdute în cazul acestei metode.

Bui și Moon [32] au propus o metodă în care un urmaș încearcă mai întâi să înlocuiască părintele cel mai similar, pe baza distanței Hamming, și, dacă nu reușește, încearcă înlocuirea celui alt părinte. Dezavantajul acestei metode constă în faptul că este consumatoare de timp, deoarece o mare diversitate implică un timp mare pentru a se obține convergența. În particular, rata urmașilor care vor fi pierduți în generațiile viitoare este extrem de ridicată. În etapele ulterioare ale algoritmului, se abandonează adesea peste 99% din urmașii generației. Pentru a se compensa acest efect, în [32] această metodă este combinată cu preselecția. Cu toate acestea, în etapele ulterioare ale algoritmului timpul consumat inutil este relativ ridicat, deoarece este dificilă generarea unui urmaș de calitate mai bună decât cel puțin unul din părinți, atunci când majoritatea membrilor populației sunt de calitate foarte bună.

În algoritmul de partiționare descris, se combină metoda de înlocuire din [32] cu cea de tip *Genitor*. Se încearcă mai întâi înlocuirea părintelui cel mai similar, pe baza distanței Hamming; dacă urmașul este de calitate mai slabă decât ambii părinți, se înlocuiește membrul cel mai inferior calitativ al populației. Scopul este de a se menține diversitatea populației, fără a se crește în mod semnificativ timpul consumat inutil. Rezultatele obținute prin această metodă combinată sunt superioare celor obținute prin metoda de tip *Genitor*.

Criteriul de terminare pentru un mare număr de algoritmi genetici este execuția pentru un număr fix de generații. Un criteriu mai avantajos este terminarea algoritmului atunci când diversitatea populației scade sub un anumit prag. Algoritmul se termină atunci când 80% a populației este ocupată cu soluții de aceeași calitate, ale căror cromozomi nu sunt neapărat aceiași. Numărul maxim de iterații este limitat la 2000.

3.7.3 Rezultate experimentale

Algoritmul de partiționare propus pentru echilibrarea numărului de conexiuni a fost implementat în limbajul C. Experimentele au fost efectuate pe un calculator IBM PC cu un procesor Pentium de 133 MHz, sub sistemul de operare Windows NT Version 4.0. S-a utilizat un număr de nouă circuite de test din cadrul setului de circuite al centrului *MCNC (Microelectronics Center of North Carolina)*. Lista de conexiuni a circuitelor de test a fost convertită din formatul *EDIF (Electronic Design Interchange Format)* în formatul listei de conexiuni utilizate de programul de partiționare. Algoritmul de partiționare a fost aplicat asupra listelor de conexiuni obținute astfel.

În Tabelul 3.1 se prezintă circuitele de test care au fost utilizate. Prima coloană a tabelului conține denumirea circuitului, iar următoarele coloane conțin numărul total de celule necesare (celule logice și celule de I/E), numărul de conexiuni și numărul de terminale ale fiecărui circuit.

Tabelul 3.1. Caracteristicile circuitelor *MCNC* utilizate pentru testare.

Circuit	Nr. celule	Nr. conexiuni	Nr. terminale
<i>b1</i>	28	24	63
<i>c17</i>	23	17	37
<i>cm138a</i>	43	32	92
<i>con1</i>	33	29	74
<i>daio</i>	30	28	71
<i>decod</i>	75	59	179

Circuit	Nr. celule	Nr. conexiuni	Nr. terminale
<i>majority</i>	21	16	45
<i>tcon</i>	82	66	171
<i>x2</i>	58	49	155

Tabelul 3.2 prezintă rezultatele experimentelor efectuate în care s-a urmărit care este valoarea tăieturii obținute în urma bipartiționării fiecărui circuit în două cazuri. Primul caz este cel în care nu se urmărește echilibrarea numărului de conexiuni din cele două partiții ($PONDERE = 0$), caz indicat în tabel prin $P = 0$. Al doilea caz este cel în care se realizează și echilibrarea numărului de conexiuni, termenul corespunzător din funcția de cost având aceeași pondere cu termenul pentru minimizarea lungimii conexiunilor ($PONDERE = 1$), caz indicat în tabel prin $P = 1$. Valorile s-au obținut prin rularea algoritmilor de 20 de ori, calculându-se media tăieturilor pentru aceste rulări (valorile fiind rotunjite la numere întregi).

Tabelul 3.2. Dimensiunea tăieturii în urma bipartiționării circuitelor.

Circuit	Dimensiune tăietură	
	$P = 0$	$P = 1$
<i>b1</i>	9	11
<i>c17</i>	4	6
<i>cm138a</i>	12	16
<i>con1</i>	12	10
<i>decod</i>	12	17
<i>majority</i>	10	14
<i>tcon</i>	11	17
<i>x2</i>	14	16

Din Tabelul 3.2 se observă că în cazul în care se urmărește și echilibrarea numărului de conexiuni din cele două partiții ($P = 1$) se obține o anumită creștere a dimensiunii tăieturii față de cazul în care se urmărește numai minimizarea lungimii conexiunilor ($P = 0$). Acest lucru este explicabil, deoarece în cazul în care $P = 0$, singura metrică utilizată este cea care indică dimensiunea tăieturii. În cazul bipartiționării, această dimensiune este cea a tăieturii din centrul circuitului. Pentru a măsura dimensiunea tăieturii și în alte zone ale circuitului, algoritmul de bipartiționare a fost aplicat recursiv până la obținerea unor zone care conțin o singură celulă, urmărindu-se care este suma tăieturilor în cele două cazuri: $P = 0$ și $P = 1$. Rezultatele sunt prezentate în Tabelul 3.3.

Tabelul 3.3. Suma tăieturilor în urma aplicării recursive a algoritmului de bipartiționare.

Circuit	Suma tăieturilor		Reducere
	$P = 0$	$P = 1$	
<i>b1</i>	19	17	10.5 %
<i>c17</i>	10	10	0.0 %
<i>cm138a</i>	38	38	0.0 %
<i>con1</i>	30	28	6.6 %
<i>decod</i>	69	59	14.5 %
<i>majority</i>	17	15	11.7 %
<i>tcon</i>	60	51	15.0 %
<i>x2</i>	51	46	9.8 %

Din Tabelul 3.3 rezultă că pentru șase din cele opt circuite s-a obținut o reducere a sumei tăieturilor, pe lângă echilibrarea numărului de conexiuni. Reducerea medie pentru circuitele de test utilizate este de 8.5 %.

3.8 Concluzii

În acest capitol a fost prezentată o problemă importantă care apare în cadrul proiectării fizice, și anume partiționarea circuitelor. Această problemă a fost prezentată atât ca o etapă de proiectare pentru divizarea unui sistem în mai multe părți care pot fi implementate prin componente separate, cât și ca o metodă algoritmică pentru rezolvarea problemelor complexe de optimizare care apar în sinteza logică sau în proiectarea fizică a circuitelor VLSI în general și FPGA în particular. Accentul este pus pe partiționarea circuitelor FPGA cu resurse limitate de rutare.

Au fost definite formulările problemei de bipartiționare și a celei de multipartiționare, fiind prezentate principalele restricții care pot fi impuse unei probleme de partiționare. Metodele de partiționare au fost clasificate ca fiind, pe de o parte, *deterministice* și *stohastice*, iar pe de altă parte, ca *iterative* sau *constructive*. Au fost descrise sintetic numeroase metode de partiționare întâlnite în literatură, atât pentru circuitele VLSI, cât și FPGA.

Problema de bipartiționare în care cele două partiții au dimensiuni egale a fost examinată mai detaliat, datorită importanței sale practice. Această partiționare este utilizată în cadrul procedurii de plasare pe baza tăieturii minime, care este descrisă în capitolul 4. În plus, un algoritm de bipartiționare poate fi utilizat pentru obținerea unei proceduri de partiționare cu k căi, prin aplicarea recursivă a algoritmului de bipartiționare de $\log_2 k$ ori. Avantajul acestei metode de multipartiționare este că procedura de bipartiționare utilizată este mai simplă decât o procedură directă de multipartiționare, dar are dezavantajul că valoarea lui k este presupusă ca o putere a lui 2.

Algoritmul Kernighan-Lin este unul din cele mai utilizate pentru rezolvarea problemei de bipartiționare. Este un algoritm cu îmbunătățire iterativă, care poate fi extins și pentru rezolvarea unor probleme mai generale de partiționare. Dintre acestea au fost prezentate următoarele cazuri: blocuri cu dimensiuni inegale, elemente cu dimensiuni inegale, și partiționarea cu k căi. O extindere a algoritmului Kernighan-Lin și o implementare mai eficientă a acestuia a fost realizată de Fiduccia și Mattheyses, euristica acestora luând în considerare atât conexiunile multipin, cât și dimensiunile elementelor de circuit.

Călirea simulată este o metodă stohastică de îmbunătățire iterativă utilizată pentru rezolvarea diferitelor probleme de optimizare, inclusiv pentru cea de partiționare. Un avantaj important al metodelor stohastice este că pot evita minimele locale. Prin metoda de călire simulată se obțin anumite avantaje în privința calității soluției, dar timpul de calcul consumat poate fi foarte ridicat.

Partiționarea prin metoda tăieturii proporționale se bazează pe o metrică propusă de Wei și Cheng, care s-a dovedit o funcție obiectiv de succes pentru numeroase aplicații. Această metodă are tendința de a identifica grupările naturale din circuit. Euristica de partiționare propusă de aceiași autori se bazează pe algoritmul Fiduccia-Mattheyses.

Deoarece performanțele algoritmului Kernighan-Lin sunt dependente de alegerea partiției inițiale, pentru a se evita blocarea în minime locale este necesar un număr mare de rulări ale algoritmului asupra unor partiții inițiale generate aleator. Cheng și Wei au propus o metodă de bipartiționare cu performanțe stabile, care nu necesită generarea unui mare număr de configurații inițiale. Se utilizează o tehnică de partiționare recursivă de sus în jos, împărțindu-se întregul circuit în grupuri mici, puternic conectate, care sunt apoi rearanjate în două subseturi care respectă restricția de dimensiune. Rezultatele sunt semnificativ mai bune față de cele obținute prin algoritmul Fiduccia-Mattheyses.

Metodele spectrale propuse în ultimii ani utilizează vectori proprii și valori proprii ale matricii de adiacență a grafului care descrie circuitul. Vectorul propriu al valorii proprii minime diferite de zero a matricii poate fi interpretat ca o plasare liniară

sau ordonare a nodurilor grafului. Această ordonare poate fi divizată pentru a obține o partiționare a nodurilor. În literatură au fost publicate numeroase modificări ale acestei metode de bază. Prin metoda spectrală a fost raportată o îmbunătățire medie de 9% a raportului de tăietură față de rezultatul obținut prin metoda tăieturii proporționale.

Metodele bazate pe fluxul în rețele utilizează fluxul direcționat al semnalelor pentru îmbunătățirea performanțelor sistemului. Diferitele metode propuse au în comun faptul că este generat un model al grafului din lista de conexiuni direcționată pentru a determina un flux maxim, care este echivalent cu o tăietură minimă. În literatură au fost raportate rezultate obținute prin aceste metode care sunt mai bune comparativ cu cele ale unor euristici de tip Kernighan-Lin, cât și cu cele ale unor metode spectrale.

A fost descrisă de asemenea o metodă probabilistică de partiționare, care poate determina implicațiile globale și viitoare ale mutării unui nod în orice etapă a procesului de partiționare. Fiecărui nod i se asociază o probabilitate a evenimentului nodul respectiv să fie mutat efectiv în celălalt subset în pasul curent al procesului de partiționare. Din această probabilitate se calculează câștigurile potențiale ale nodurilor, ceea ce reprezintă o indicație corectă a beneficiului care se obține în urma mutării acestora în celălalt subset.

Au fost descrise și unele metode neconvenționale de partiționare: partiționarea prin evoluție stohastică și cea prin automate de învățare. Metoda de evoluție stohastică descrisă pentru soluționarea problemei de bipartiționare presupune că nodurile circuitului au dimensiuni diferite. A fost descrisă de asemenea extinderea algoritmului de bipartiționare pentru problema de multipartiționare. Automatul de învățare descris este numit automat pentru migrarea obiectelor. Acest automat modifică stările tuturor obiectelor, spre deosebire de automatul tradițional la care obiectele sunt trecute dintr-o stare în alta. Atunci când acest automat este utilizat pentru rezolvarea problemei de partiționare, o soluție nu este definită prin starea curentă a automatului, ci prin întreaga structură a acestuia.

În cadrul capitolului s-au propus doi algoritmi de bipartiționare pentru circuitele FPGA cu resurse limitate de rutare. Primul algoritm se bazează pe metoda tăieturii minime, și urmărește echilibrarea numărului de conexiuni din cadrul partițiilor, minimizând în același timp lungimea totală a interconexiunilor. A fost propusă o metrică mai adecvată pentru partiționarea utilizată la plasarea circuitelor FPGA la care principalul obiectiv este asigurarea rutabilității. Experimentele efectuate arată că prin aplicarea acestui algoritm se obține o reducere a dimensiunii tăieturii, ceea ce va avea ca efect reducerea necesarului de resurse de interconectare a circuitului FPGA, atunci când algoritmul este utilizat pentru rezolvarea problemei de plasare.

Al doilea algoritm propus este un algoritm genetic pentru partiționare, cu un obiectiv similar cu primul algoritm. Algoritmul utilizează doi operatori de încrucișare în loc de unul singur, al doilea operator fiind prevăzut pentru situația în care doi cromozomi sunt exact complementul unuia față de celălalt, și deci aceștia reprezintă aceeași bisecție. În acest caz, primul operator ar crea un cromozom urmaș cu o calitate redusă. Metoda de înlocuire utilizată este diferită de cea a algoritmilor tradiționali, având ca scop principal menținerea diversității populației. Criteriul de terminare este de asemenea diferit, algoritmul fiind terminat atunci când diversitatea populației scade sub un anumit prag. Algoritmul a fost comparat cu un algoritm de partiționare prin metoda călirii simulate. Experimentele au arătat că timpul de execuție al algoritmului genetic este mai redus, rezultatele obținute fiind comparabile cu cele obținute prin metoda călirii simulate.

Contribuțiile acestui capitol sunt următoarele:

- Propunerea unei metrici mai adecvate pentru partiționarea utilizată la plasarea circuitelor FPGA cu resurse limitate de rutare;

-
- Elaborarea și testarea unui algoritm de partiționare care urmărește echilibrarea numărului de conexiuni din cadrul partițiilor, minimizând în același timp lungimea totală a interconexiunilor;
 - Elaborarea și testarea unui algoritm genetic pentru partiționare, cu un timp de execuție mai redus decât cel al unui algoritm bazat pe metoda călirii simulate, calitatea soluțiilor obținute fiind comparabilă cu cea obținută prin metoda călirii simulate.