

**UNIVERSITATEA DIN CRAIOVA
FACULTATEA DE AUTOMATICĂ, CALCULATOARE ȘI
ELECTRONICĂ**

TEZĂ DE DOCTORAT

**ALGORITMI PENTRU CREȘTEREA VITEZEI
DE TRANSFER AL INFORMAȚIEI ÎN BAZE DE
DATE DISTRIBUITE**

- REZUMAT -

Doctorand
ADRIAN RUNCEANU

**Conducător științific:
Prof. Univ. Dr. Ing. MIRCEA PETRESCU**

2009

Această teză prezintă câteva implementări legate de problema fragmentării datelor în general, iar în caz particular proiectarea partaționării verticale atât pentru bazele de date distribuite relaționale, cât și pentru bazele de date distribuite orientate-obiect, și fragmentarea orizontală împreună cu alocarea datelor în cazul bazelor de date distribuite orientate-obiect..

1. Astfel s-a studiat aplicarea câtorva algoritmi de grupare pentru procesul de proiectare a bazelor de date distribuite. Anumiți algoritmi, cum a fi algoritmul erorii-pătrate au fost adaptati și implementați pentru fragmentarea verticală a datelor.

2. S-a prezentat o funcție obiectivă pentru n partiții, compusă din doi termeni care furnizează o evaluare bună pentru micșorarea costului proceselor de tranzacții.

3. Funcția prezentată se poate modifica prin adăugarea unor informații noi legate de tipurile de interogări (de actualizare sau de regăsire de date), de informații legate de alocarea datelor în rețea și de costul procesului de acces la datele aflate la distanță.

4. Alocarea fragmentelor s-a prezentat printr-o abordare euristică care propune – în cazul bazelor de date distribuite orientate-obiect – o variantă care combină fragmentarea instanțelor claselor în același timp cu alocarea datelor pe diferite site-uri.

Teza de doctorat este structurată în 7 capitole următe de anexe și bibliografie.

În **Capitolul 1 „Introducere”** se prezintă principalele aspecte legate de proiectarea bazelor de date distribuite.

Procesul de proiectare a bazelor de date distribuite este un proces de optimizare care necesită obținerea unor soluții la câteva probleme care se întrepătrund, și anume fragmentarea datelor, alocarea datelor și optimizarea locală. Fiecare problemă poate fi rezolvată cu ajutorul unor abordări diferite și din această cauză proiectarea bazelor de date distribuite devine o activitate foarte dificilă. De obicei faza de proiectare este prin definiție de tip euristic.

Proiectarea bazelor de date distribuite derivă din proiectarea bazelor de date non-distribuite doar în ceea ce privește aspectul distribuit. Faza de proiectare implică achiziția de date, partaționarea bazei de date, alocarea și replicarea partițiilor și optimizarea locală. Partaționarea bazei de date se poate efectua în câteva modalități diferite: partaționare verticală, orizontală și hibridă (numită și mixtă). Acest aspect al proiectării bazelor de date va fi evidențiat în această teză și anume dezvoltarea unui algoritm de verificare a diferenților algoritmi propuși în literatura de specialitate în cazul partaționării (fragmentării) bazelor de date distribuite.

În principal, va fi luată în discuție problema partaționării (fragmentării) verticale a datelor, cunoscută și sub denumirea de partaționarea atributelor. Această tehnică se utilizează la proiectarea bazelor de date pentru îmbunătățirea performanțelor tranzacțiilor. În partaționarea verticală, atributele unei relații R sunt puse împreună în grupuri care nu se suprapun și relația R se proiectează în fragmente de relații conform cu aceste grupuri de atribut.

În sistemele de baze de date distribuite, aceste fragmente se alocă pe site-uri diferite. De aici vine obiectivul partaționării verticale de a crea fragmente verticale ale unei relații astfel încât să se minimizeze costul accesării datelor în timpul procesului de tranzacții. Dacă fragmentele se aproprie cât mai mult de necesitățile mulțimii de tranzacții oferite, atunci costul procesului de tranzacții poate fi micșorat.

În cazul proiectării bazelor de date distribuite, costul procesului de tranzacționare se micșorează prin mărirea tranzacțiilor locale (pe un site) și în același timp prin reducerea cantității de accesări de date care nu sunt locale. Scopul tehnicii de partaționare verticală (și în general, a tehniciilor de partaționare) este de a găsi o schemă de partaționare care să îndeplinească obiectivul prezentat anterior.

De notat faptul că problema partaționării poate fi abordată pe diferite niveluri de detaliu prin luarea în considerare a unor informații adiționale.

Fragmentarea datelor. În această teză, se i-au în considerare doar informațiile despre tranzacții ca dată de intrare, pentru a putea gestiona problema partaționării într-un mod eficient. De fapt, problema optimizării globale (care include un număr mare de parametri și o metrică

complexă) se împarte în câteva probleme mai mici de optimizare pentru a putea reduce spațiul de căutare și a putea reduce complexitatea fiecărei probleme în parte.

În literatura de specialitate sunt propuși câțiva algoritmi de partitioare verticală, astfel se măsoară afinitatea dintre perechi de attribute și se încearcă să se grupeze attributele împreună conform afinității între perechi de attribute, cu ajutorul algoritmului BEA (*bond energy algorithm*). Într-un articol se folosește un estimator euristic de cost a proiectării unui fișier pentru a obține o schemă de partitioare “de jos-în-sus”. În alt articol se extinde abordarea propusă de algoritmul BEA și se prezintă două faze pentru partitioarea verticală. Algoritmii de partitioare menționați anterior utilizează câteva metode euristice pentru a fragmenta o relație.

Ca dată de intrare a acestor algoritmi se folosește matricea de utilizare a atributelor (AUM). Această matrice are attribute ca și coloane și tranzacții ca și linii, iar frecvența accesării tranzacțiilor ca valori în matrice. Majoritatea algoritmilor anteriori folosesc la fragmentarea datelor, utilizează matricea de afinitate a atributelor (AAM) care este derivată din AUM. AAM este o matrice în care pentru fiecare pereche de attribute, se stochează suma totală a frecvenței de acces a tranzacțiilor care acceseză acea pereche de attribute. Rezultatele diferenților algoritmi sunt deseori diferențe, chiar dacă pentru aceeași matrice de afinitate a atributelor, se indică faptul că funcțiile obiective folosite sunt diferențe. Majoritatea algoritmilor de partitioare verticală nu dispun de o funcție obiectivă pentru evaluarea corectitudinii partitiilor care se obțin în urma aplicării acestor algoritmi. De asemenea, nu există un criteriu comun sau o funcție obiectivă care să evaluateze rezultatele acestor algoritmi de partitioare verticală.

În **Capitolul 2 „Câteva concepte de bază”** prezintă câteva noțiuni de bază referitoare la bazele de date distribuite. Astfel sunt trecute în revistă modele de reprezentare a bazelor de date relaționale, distribuite și orientate-obiect.

Astfel sunt descrise sistemele de baze de date în general, concentrându-se pe componentele lor software. Apoi se prezintă modelul de date relațional și câțiva operatori ai limbajului structurat de interogare (SQL).

Modelele de baze de date cele mai răspândite până în acest moment sunt modelul relațional și modelul care a reușit să se impună în ultimii ani ca un model foarte bun, și anume modelul orientat-obiect, sunt prezentate pe larg.

În ultimii ani, bazele de date distribuite (BDD) au devenit un sector important al prelucrării informației și se poate anticipa că importanța lor va crește rapid. Această tendință este motivată atât organizatoric cât și tehnologic întrucât BDD elimină multe din neajunsurile BD centralizate și sunt bine venite pentru descentralizarea structurilor organizatorice.

O BDD poate fi definită ca o colecție de date integrate din punct de vedere logic dar fizic distribuite pe stații ale unei rețele de calculatoare.

Această definiție pune în evidență două aspecte importante ale BDD:

1. Integrarea logică a colecțiilor de date. Din punct de vedere al utilizatorului există o singură bază de date cu care utilizatorul interacționează la fel ca și în cazul bazelor de date centralizate (BDC).

2. Distribuirea fizică se referă la partitioarea fizică a bazei de date pe spații ale unei rețele de calculatoare.

Ambele aspecte sunt destul de vagi pentru a realiza deosebirile între BDD și un set de baze de date (BD) locale. În timpul operațiilor obișnuite, cererile de aplicații de la terminalele fiecărei stații necesită numai accesul la BD locală. Aceste aplicații care sunt executate în întregime de computerul stației sunt numite **aplicații locale**.

Ceea ce deosebește un set de BD locale de o BDD este existența unor aplicații care acceseză date din mai multe stații. Aceste aplicații sunt numite **aplicații globale** sau aplicații distribuite. Se poate însuma considerațiile pe care le-am făcut într-o definiție de lucru.

O **BDD** reprezintă o colecție de date integrate din punct de vedere logic care sunt fizic distribuite pe stații ale unei rețele de calculatoare. Fiecare stație a rețelei are autonomie de

prelucrare care îi permite să realizeze aplicații locale. De asemenea, fiecare stație participă la execuția aplicațiilor globale care necesită accesarea datelor din mai multe stații.

Controlul centralizat. Posibilitatea de a realiza un control centralizat asupra resurselor informaționale ale unei întreprinderi sau structuri organizatorice a fost considerată una din cele mai puternice motivații pentru introducerea BD. Funcția fundamentală a administratorului BD este de a garanta protecția și siguranța datelor; datele în sine fiind recunoscute ca o investiție importantă a întreprinderilor care necesită un control centralizat.

În cazul BDD ideea controlului centralizat este puțin accentuată. Acest lucru depinde și de arhitectură. În general, putem să identificăm o structură de control ierarhic bazată pe un **administrator global** care are responsabilitatea centrală a întregii BDD și pe administratorii locali cărora le revin responsabilități legate de BD locale. Administratorii locali pot avea un grad înalt de autonomie care poate merge până la realizarea coordonării între stații. BDD diferă foarte mult în ceea ce privește autonomia stațiilor de la autonomia completă a stațiilor, fără existența administratorului global, până la cel mai complet control centralizat.

Independența datelor. În cazul BDD asigurarea independenței datelor față de programele de aplicații are aceeași importanță ca și în cazul BDC, dar apare un nou aspect legat de **transparența distribuției**. Prin transparența distribuției programele pot fi scrise făcând abstracție de distribuirea fizică a datelor. Mutarea datelor dintr-o stație în alta afectează numai viteza de execuție, nu și corectitudinea programului.

Ca și în cazul independenței datelor, transparența distribuției este obținută printr-o arhitectură multinivel cu diferite descrieri ale datelor.

Asigurarea unei redundanțe minime și controlate. În cadrul BDD există mai multe motive pentru a considera redundanța datelor o caracteristică dezirabilă:

- localizarea este mai rapidă atunci când datele sunt replicate la toate stațiile unde sunt cerute de aplicații;
- disponibilitatea, siguranța sistemului crește atunci când datele sunt replicate. În cazul căderii unei stații, aplicațiile pot fi dirijate la stațiile unde datele sunt replicate.

Redundanța datelor reduce efortul de regăsire a datelor dar crește efortul de actualizare. Evaluarea unui grad optim al redundanței trebuie să țină seama de raportul între accesele de regăsire și accesele de actualizare a datelor.

Integritatea, restaurarea datelor și controlul concurenței. În cazul BDD, realizările în domeniul integrității, restaurării datelor și controlul concurenței, deși se referă la probleme diferite, sunt puternic interconectate. Într-o mare măsură, soluțiile la aceste probleme sunt legate de modul de realizare a tranzacțiilor. **O tranzacție** este o unitate atomică de execuție, o secvență de operații care fie sunt realizate în întregime, fie nu sunt realizate. În cadrul BDD, problema atomicității tranzacțiilor capătă un aspect particular legat de modul în care trebuie să se comporte sistemul atunci când una din stații nu este operațională: să aborteze întreaga tranzacție sau să încece să execute corect tranzacția chiar dacă ambele stații nu sunt simultan operaționale.

Siguranța și securitatea datelor. În BD tradiționale, administratorul BD care are controlul centralizat permite numai un acces autorizat la date. În BDD, administratorii se confruntă cu aceleași probleme ca administratorii BD tradiționale. Sunt de menționat două aspecte particulare:

- în BDD, cu un grad ridicat de autonomie a stațiilor, BD locale sunt mai protejate deoarece administratorii locali își realizează propria protecție fără să depindă de un administrator centralizat;
- problemele securității sunt intrisici sistemelor distribuite deoarece comunicația în rețea poate reprezenta un punct slab în realizarea protecției.

În **Capitolul 3 „Arhitecturi ale bazelor de date distribuite”** sunt prezentate principalele arhitecturi ale bazelor de date distribuite, iar **capitolul 4 „Serverul se baze de date”** propune spre prezentare serverul de baze de date Oracle.

Capitolul 5 „Fragmentarea bazelor de date distribuite” este principalul capitol al acestei teze deoarece prezintă pe larg ce înseamnă fragmentarea datelor în cazul bazelor de date distribuite, pornind de la tipuri de fragmentare și reguli de fragmentare a datelor, trecând prin prezentarea fragmentărilor orizontale, verticale și hibride(mixte), până la utilizarea algoritmilor de grupare în fragmentarea datelor, caz particular, fragmentarea verticală atât în cazul bazelor de date distribuite relaționale, cat și în cazul bazelor de date distribuite orientate-obiect.

Acest capitol prezintă toate noțiunile necesare înțelegерii și aplicării procesului de fragmentare a datelor în bazele de date distribuite, atât în varianta relațională cât și în varianta orientată-obiect.

Astfel sunt descrise motivele pentru care se utilizează fragmentarea în procesul de proiectare a bazelor de date distribuite, împreună cu tipurile cunoscute de fragmentare, la modul general și exemplificate cu ajutorul unei scheme de bază de date. Se prezintă gradul de fragmentare a unei baze date și se stabilesc care sunt regulile de fragmentare care trebuie să fie îndeplinite în procesul proiectării bazelor de date distribuite.

Din punct de vedere a distribuției datelor, nu este necesar să se fragmenteze datele. În definitiv, în sistemele de fișiere distribuite, distribuția se execută pe baza tuturor fișierelor. În fapt, prelucrarea datelor se face cu ajutorul alocării fișierelor în nodurile unei rețele.

În fragmentare, principala caracteristică este să apropie unitățile de distribuție. O relație nu este o unitate convenabilă din mai multe motive:

- În primul rând vederile aplicației sunt de obicei submulțimi de relații. De aceea, localizarea accesului la aplicații este definită nu pe toate relațiile ci pe submulțimi ale lor. De aici este natural să considerăm submulțimile relațiilor ca *unitate de distribuție*.
- În al doilea rând, dacă aplicațiile care au vederi definite pe o relație dată, se află pe site-uri diferite, atunci se pot urmări două alternative având întreaga relație ca unitate de distribuție:
 - Pe de o parte, relația nu este replicată (copiată) și este memorată pe un singur site;
 - Pe de altă parte este replicată pe toate site-urile sau pe unele dintre site-uri unde sunt aplicațiile.

Prima variantă necesită un volum mare și neeficient de acces controlat la date de la distanță. A doua variantă, pe de altă parte oferă o replicare neeficientă (nenecesară), care cauzează probleme în execuția actualizărilor și ar putea să nu fie dorită dacă, capacitatea de memorare este limitată.

În sfârșit, descompunerea unei relații în fragmente, fiecare tratată ca o unitate, permite ca un număr de tranzacții să fie executate concurențial.

În plus, fragmentarea relațiilor rezultă în mod tipic din execuția în paralel a unei singure interogări prin împărțirea într-o mulțime de subinterogări care operează pe fragmente. De aici fragmentarea mărește nivelul concurenței.

Trebuie totuși, amintite și dezavantajele fragmentării. Dacă aplicațiile au cerințe conflictuale care previn descompunerea relației în fragmente exclusive, acele aplicații ale căror vederi sunt definite pe mai mult de un fragment pot suferi degradări din punct de vedere al performanței. De exemplu, ar fi necesar să recuperăm date din două fragmente și aceasta s-ar putea obține ori prin uniune, ori prin juncțion, ceea ce ar fi o operație destul de costisitoare. Evitarea acestui aspect este o caracteristică importantă a fragmentării.

A doua problemă se referă la controlul semantic al datelor, mai ales la verificarea integrității datelor. Ca rezultat al fragmentării, atributele participante în dependențe pot fi descompuse în diferite fragmente care vor fi alocate pe diferite site-uri. În acest caz, chiar și cea mai simplă acțiune de verificare a dependențelor se va executa prin urmărirea datelor pe un număr de site-uri.

Fragmentarea orizontală. Există două variante ale fragmentării orizontale: *fragmentare primară* și *fragmentare derivată*.

Factorii care influențează fragmentarea: structura bazei de date (schema conceptuală globală) și caracteristicile aplicației (predicalele folosite, locațiile unde sunt stocate, frecvențele de acces) – regula “80/20” (20% din interogările utilizator folosesc 80% din datele gestionate în acea bază de date).

Aplicațiile (pe care le putem considera ca fiind interogări) care accesează o bază de date, selectează o submulțime de date pe baza unui predicat – adică a unei expresii booleene.

În proiectarea bazelor de date trebuie să identificăm „grupuri” de tupluri din baza de date care sunt accesate împreună de către aplicații/interogări. Fiecare „grup” este definit ca un predicat „minterm”, care este de fapt o combinație de predicate simple. Aceste „grupuri” devin apoi candidați pentru fragmentele orizontale.

Informații cantitative: $Selectivitatea minterm = sel(m_i)$ (selectivitatea unui minterm m_i) și $Frecvența de acces = acc(q_i)$ (frecvența de acces a interogării q_i).

Algoritmul de partitioare orizontală este analizat și se evidențiază pașii care trebuie parcursi pentru a obține predicatele minterm necesare fragmentelor orizontale:

Pas 1. Construirea unei mulțimi de predicate simple care să fie completă și minimală.

Pas 2. Generarea mulțimii de predicate minterm.

Pas 3. Eliminarea unor predicate minterm necontradictorii.

Fragmentarea orizontală derivată se definește pe o relație membru a unei legături în conformitate cu operația de selecție specificată pe proprietarul său.

Fragmentarea verticală. Se știe că fragmentarea verticală a unei relații R produce fragmentele R_1, R_2, \dots, R_n , fiecare conținând o submulțime de atribute ale lui R la fel ca o cheie primară a lui R.

Obiectivul fragmentării verticale este să particioneze o relație într-o submulțime de relații mai mici astfel încât aplicațiile utilizator să ruleze numai pe un fragment.

Există două tipuri de abordări în fragmentarea verticală pe relațiile globale:

Gruparea: începe prin asocierea fiecărui atribut unui fragment, și la fiecare pas, unificarea fragmentelor până când criteriul este îndeplinit.

Diviziunea (partiționarea): începe cu o relație și decide care sunt partiile utile, în conformitate cu comportamentul aplicațiilor la accesarea atributelor.

Informațiile necesare fragmentării verticale. În faza de proiectare, fragmentarea verticală are nevoie de următoarele două informații: care aplicații/interogări folosesc atribute și care sunt acestea frecvența cu care diferite aplicații/interogări se execută.

Prima informație va fi stocată într-o matrice numită matricea de utilizare a atributelor.

Principala informație referitoare la aplicații se referă la frecvența de acces.

Fie $Q = \{ q_1, q_2, \dots, q_q \}$ mulțimea de interogări (aplicații) utilizator care rulează pe relația $R(A_1, A_2, \dots, A_n)$. Atunci, pentru fiecare interogare q_i și pentru fiecare atribut A_j , vom asocia o valoare de utilizare a atributului, notată cu $use(q_i, A_j)$, și definită astfel:

$$use(q_i, A_j) = \begin{cases} 1 & \text{daca atributul } A_j \text{ este utilizat de interogarea } q_i \\ 0 & \text{altfel} \end{cases}$$

Vectorii $use(q_i, *)$ pentru fiecare aplicație sunt ușori de definit dacă proiectantul cunoaște aplicațiile care vor rula pe baza de date.

Valorile de utilizare a atributelor nu sunt suficiente – în general – pentru a forma baza împărțirii atributelor și a fragmentării. Aceasta este deoarece aceste valori nu reprezintă greutatea frecvenței aplicațiilor. Măsurarea frecvenței poate fi inclusă în definiția măsurării afinității atributelor, pe care o putem nota prin $aff(A_i, A_j)$, care măsoară legătura între două atribute ale unei relații în conformitate cu cât sunt ele accesate de aplicații.

Măsurarea afinității dintre două atribute A_i și A_j ale unei relații $R(A_1, A_2, \dots, A_n)$ cu respectarea unei mulțimi de aplicații $Q = \{ q_1, q_2, \dots, q_q \}$ este definită astfel

$$aff(A_i, A_j) = \sum_{k | use(q_k, A_i) = 1 \wedge use(q_k, A_j) = 1 \forall S_l} \sum_{ref_l(q_k)} ref_l(q_k) acc(q_k)$$

unde:

$ref_l(q_k)$ este numărul de accesări ale atributelor (A_i, A_j) pentru fiecare execuție a aplicației q_k pe site-ul S_l

și $\text{acci}(q_k)$ este măsura frecvenței de accesare a aplicației definită mai înainte dar modificată pentru a include în definiție frecvența pe site-uri diferite.

Algoritmul de grupare (clustering algorithm) aduce împreună atributelor cu valori ale afinităților mai mari și separat cele cu valori ale afinităților mai mici. Algoritmul de grupare primește la intrare matricea AA , permută liniile sau coloanele acesteia (este indiferent pe care le permute deoarece matricea este simetrică) și generează matricea legăturilor de afinitate CA (clustered affinity matrix). Permutarea este făcută astfel încât să maximizeze măsura afinității globale (global affinity measure).

Generarea matricei legăturilor de afinitate (CA) este realizată în trei pași, implementați în algoritmul `GEN_CLUS_ATR`:

Initializarea – se plasează și se fixează o coloană arbitrară a matricei AA în matricea CA (în algoritm a fost aleasă coloana 1)

Iterația – se alege o coloană dintre cele $n-i$ rămase (i este numărul coloanelor deja plasate în CA) și se plasează în cele $i+1$ poziții rămase, se va alege plasarea coloanei care aduce cea mai mare contribuție la măsura afinității globale descrisă mai sus. Se continuă acest pas până când nu mai sunt coloane de plasat.

Ordonarea liniilor – se schimbă poziționarea liniilor astfel încât să fie păstrată simetria.

Algoritmul de partiționare (partitioning algorithm) are obiectiv activitatea de partaționare (diviziune) și anume găsirea unei mulțimi de atrbute care sunt accesate independent sau (în majoritatea cazurilor) de mai multe mulțimi distincte de aplicații.

În secțiunea 5.7 se propune o modalitate de evaluare a unei scheme de partaționare a datelor în bazele de date distribuite relationale. Astfel se propune un algoritm de evaluare a fragmentelor rezultate în faza de proiectare a bazelor de date distribuite și se analizează algoritmul pe câteva cazuri propuse.

În orice aplicație practică de baze de date, o tranzacție nu necesită ca în mod obișnuit toate atrbutele tuplurilor unei relații să fie recuperate în timpul procesului unei tranzacții. Când o relație este împărțită *vertical* în fragmente de date, atrbutelor stocate în fragmente de date care sunt irelevante (adică nu sunt accesate de tranzacție), li se adaugă un cost de recuperare și procesare, în special când numărul de tupluri implicate în relație este foarte mare.

În sistemele de gestiune a bazelor de date distribuite, când un atrbut relevant (adică un atrbut care este accesat într-o tranzacție) se află în fragmente de date diferite și care sunt alocate pe diferite site-uri, atunci se adaugă un cost adițional pentru accesul la aceste date. De aceea una din caracteristicile dorite la sistemele de gestiune a bazelor de date distribuite pe care dorim să o atingem prin partaționare este *accesibilitatea locală* la orice site. Cu alte cuvinte, fiecare site trebuie să fie capabil să proceseze tranzacții *locale cu acces minim* la datele localizate pe alte site-uri.

Ideal, dorim ca orice tranzacție să acceseze doar acele atrbute dintr-un singur fragment de date fără acces deloc sau minim la atrbutele irelevante din acel fragment. Dar este imposibil să atingem acest caz din moment ce tranzacțiiile accesează diferit și suprapus submulțimi de atrbute ale unei relații. Mai mult decât atât, tranzacțiiile se execută pe site-uri diferite și de aici unele dintre fragmentele de date care conțin atrbute relevante ale unei tranzacții pot fi găsite în site-uri aflate la distanță. Costul procesului de tranzacții într-un mediu distribuit constă din costul procesului de tranzacții locale și costul procesului de tranzacții la distanță. Chiar dacă este posibil să replicăm datele pentru a evita costul procesului, pentru primul pas presupunem că nu avem date redundante pentru a evita modelarea suprapusă și a asigura integritatea și consistența datelor și de asemenea costul adițional al stocării.

Presupunem că în timpul procesului de proiectare a bazelor de date, faza partaționării este urmată de faza alocării în timpul căreia fragmente de date nesuprapuse obținute la faza partaționării sunt alocate pe diferite site-uri, posibil cu ceva replicare. Deci evaluatorul de partaționare propus va evalua schemele de partaționare verticală în care fragmentele de date sunt nesuprapuse pe atrbute. Aici nesuprapuse se referă doar la atrbutele cheilor neprimare. Cheia primară este rezervată în fiecare partiție. Aceasta este necesară pentru a obține relația originală fără a pierde sau a adăuga tupluri.

Scopul partiționării atributelor și alocării lor pe diferite site-uri, a ajuns la costul minim al procesării pentru orice tranzacție inițiată din orice site. Cum costul proceselor de tranzacții are două componente, una referitoare la procesarea locală și alta referitoare la procesarea la distanță (remote), evaluatorul de partiționare propus care masoară “eficacitatea” schemei de partiționare verticală, are de asemenea doi termeni corespunzători: termenul “*costul accesului local la atributele irelevante*”, și respectiv, la termenul “*costul accesului la atributele relevante la distanță*”.

Pentru a simplifica, presupunem că un singur acces la fragmente de date corespunde cu o unitate de cost; această presupunere poate fi ușorătată dacă sunt disponibile mai multe informații referitoare la metodele de acces, parametrii rețelei, etc. Termenul de cost al accesului la atributele irelevante măsoară costul procesării locale a tranzacțiilor care se fac referitor la atributele irelevante din fragmentele de date care sunt accesate la distanță de tranzacții; de notat că această contribuție la costul de acces la distanță la atributele irelevante este deja inclusă în primul termen.

Din moment ce nu se cunoaște în timpul partiționării cum sunt alocate fragmentele de date, se va calcula al doilea termen presupunând că fragmentele de date necesare unei tranzacții sunt localizate pe site-uri diferite. În absența oricărei informații referitoare la strategiile execuțării tranzacțiilor, putem calcula al doilea termen fie prin determinarea mediei aritmetice a tuturor costurilor de acces la distanță obținute prin execuția tranzacției la fiecare site ce conține un fragment necesar tranzacției sau prin presupunerea că tranzacția va rula pentru prima dată pe fragmentele site-urilor. Dacă sunt disponibile mai multe informații referitoare la strategiile de tranzacții, se pot introduce și acestea în al doilea termen.

Secțiunea 5.8 propune, în mod asemănător cu secțiunea precedentă, o modalitate de evaluare a unei scheme de partiționare a datelor în bazele de date distribuite orientate-obiect. Algoritmul propus în secțiunea anterioară este adaptat pentru a se putea aplica în cazul bazelor de date distribuite orientate-obiect, studiindu-se câteva cazuri în funcție de metodele și atributele specifice abordării orientate-obiect.

În abordarea relațională fragmentarea lucrează cu algoritmi care se aplică la distribuția atributelor. În funcție de tipul de fragmentare, sunt necesare informații despre frecvența tranzacției, utilizarea atributelor, sau despre tipul predicatelor. Se știe că avem nevoie de 4 categorii de informații pentru a ajunge o proiectare optimă:

1. Informații despre baza de date care includ schema conceptuală globală.
2. Informații despre aplicație: predicate utilizate (pentru fragmentarea orizontală), sau matricea utilizării atributelor și frecvența tranzacțiilor (pentru fragmentarea verticală).
3. Informații despre comunicarea în rețea.
4. Informații despre sistemul de calculatoare.

Totuși, în abordarea orientată-obiect schema conceptuală poate fi mult mai complexă și diferită de caracteristicile prezentate în abordarea relațională, aspectele adiționale trebuie să fie luate în considerare, cum ar metodele, structura ierarhică și atributele complexe.

Acste noi caracteristici măresc numărul de posibile abordări pentru fragmentare. De exemplu, partiționarea claselor poate implica:

- Găsirea unei “afinități” între clase (toate obiectele unei clase reprezintă o entitate aici; nu putem fragmenta atributele și metodele). “Afinitatea” dintre clase poate fi găsită în mod similar ca la atributele din abordarea relațională.
- Unificarea claselor și obiectelor și găsirea “afinității” dintre atrbute.
- Distribuirea metodelor folosind frecvența accesării lor prin tranzacții specifice urmate de fragmentarea atributelor corespunzătoare pe care aceste metode le accesează.
- Utilizarea frecvenței de acces a atributelor pentru partiționarea obiectelor unei clase urmată de distribuția corespunzătoare a metodelor.
- Urmărirea structurii ierarhice a claselor.

În procesul dezvoltării unui model de fragmentare, am studiat un sigur caz luat în considerare și anume utilizarea atributelor simple și metodelor simple.

În această categorie avem doar o ierarhie simplă, unde metodele pot folosi atributele din propria lor clasă și/sau din superclasa lor. Nu avem metode imbricate sau obiecte ca un tip de atribut. Am folosit alte matrici de utilizare, față de abordarea relațională și anume matricea de utilizare tranzacție-metodă – TMUM, matricea de utilizare metodă-atribut – MAUM. Matricea de utilizare tranzacție-metodă – TMUM este matricea frecvențelor care indică dacă tranzacția folosește anumite metode. Valorile utilizate sunt zero sau unu și reprezintă: *nu folosește sau folosește* metoda specificată. Matricea de utilizare metodă-atribut – MAUM este matricea care reprezintă numărul de invocări ale unui atribut specific într-o singură execuție a metodei. Sunt posibile trei valori:

- zero – care indică că o metodă nu acceseează un atribut.
- unu – care indică că o metodă citește valoarea unui atribut (retrieve).
- doi – indică că o metodă citește și scrie valoarea unui atribut (update).

În algoritmul propus trebuie să specificăm următoarele:

Pas 1. Să se specifice, atât în matricea TMUM cât și în MAUM toate metodele utilizate și atributele de la rădăcină până la nivelul ierarhic final al structurii bazei de date pe care se aplică acest algoritm. *Dacă clasele de pe nivelele mai mari decât i există, atunci pentru fiecare din aceste clase reprezentăm frecvența de acces a atributelor și metodelor ca o sumă a valorilor corespunzătoare.* De precizat aici, dacă o clasă are subclase, suma va include toate frecvențele metodelor și atributelor acelei clase și ale tututor subclaselor ei.

Pas 2. Înmulțim fiecare linie din TMUM cu valorile corespunzătoare ale frecvenței de tranzacție.

Pas 3. Înmulțim TMUM cu MAUM.

Pas 4. Aplicăm o căutare exhaustivă și calculăm valoarea evaluatorului de partiții pentru a selecta cea mai bună schemă de fragmentare.

Pas 5. Transmitem fragmentarea obținută.

Scopul partiționării atributelor este de a obține un proces de cost minim pentru o mulțime de tranzacții și pentru utilizarea atributelor lor. Este puțin probabil obținerea unei scheme de fragmentare ideală, unde fiecare tranzacție acceseează local numai atributele de care are nevoie și nu mai are nevoie să execute nici o accesare la distanță. Funcția obiectivă propusă aici încearcă să echilibreze costul accesului local și al celui la distanță pentru o tranzacție dată. Conform cu costul total al procesului de tranzacții într-un mediu distribuit constă din două elemente:

1. Prima componentă, numită **costul accesului la atributele locale irelevante**, reprezintă costul accesării atributelor irelevante când se acceseează un obiect într-un site local.

2. A doua componentă, numită **costul accesului atributelor relevante aflate la distanță**, include costul accesării atributelor revelante de către o tranzacție de la site-urile aflate la distanță.

Capitolul 6 „**Alocarea fragmentelor**” prezintă modalități de alocare a datelor în bazele de date distribuite, și propune o abordare împreună a celor două etape din proiectarea bazelor de date distribuite, și anume fragmentarea datelor și alocarea lor. Algoritmul prezentat este analizat împreună cu un algoritm clasic de fragmentare orizontală și se evidențiază, pe baza urmării experimentale, că este mai avantajos din punct de vedere al proiectării unei baze de date distribuite, să se efectueze atât fragmentarea datelor orizontale, cât și alocarea lor pe site-urile rețelei pe care se proiectează acea bază de date distribuită.

Capitolul 7 „**Concluzii și dezvoltări ulterioare**” prezintă, în primul rând contribuțiile originale propuse în cadrul acestei teze de doctorat, iar apoi câteva idei de dezvoltare ulterioară și de îmbunătățire a algoritmilor care sunt propuși în cadrul tezei de doctorat.

Contribuțiile personale aduse de această lucrare la domeniul abordat sunt următoarele:

Prezentarea unor algoritmi clasici din domeniul fragmentării bazelor de date distribuite, în funcție de tipurile de fragmentări de informații, și anume, în cazul fragmentării orizontale primare am prezentat algoritmul de partiționare orizontală, iar în cazul fragmentării orizontale derivate am prezentat algoritmul de fragmentare orizontală derivată.

Pe de altă parte, în cazul fragmentării verticale am prezentat algoritmii BEA (Bond Energy Algorithm) și BVP (Binary Vertical Partitioning).

Propunerea unei modalități de evaluare a schemei de partitioanare a datelor într-o bază de date distribuită relațională – algoritmul EP.

Propunerea unei modalități de evaluare a schemei de partitioanare a datelor într-o bază de date distribuită orientată-obiect – algoritmul EPOO.

Propunerea unei abordări euristică de fragmentare orizontală și alocare a fragmentelor în aceeași fază a proiectării bazelor de date distribuite orientate-obiect. Studiu comparativ între această abordare și un algoritm propus anterior.

Studierea performanțelor algoritmului propus într-o lucrare pe diferite date de test și analiza rezultatelor obținute cu evidențierea faptului că este un algoritm util în optimizarea proiectării bazelor de date distribuite relaționale fragmentate vertical la care nu trebuie precizat de la început numărul total de partiții. Acest studiu a fost prezentat la International Joint Conferences on Computer, Information, Systems Sciences, and Engineering (CISSE 2007) Conference, Conference Proceedings book, 2007, University of Brigepor, USA, și publicat în *Innovations and Advanced Techniques in Systems, Computing Sciences and Software Engineering, Springer Science*, ISBN 978-1-4020-8734-9, e-ISBN 978-1-4020-8735-6.

Studierea performanțelor algoritmului propus în altă lucrare pe diferite date de test și analiza rezultatelor obținute cu evidențierea faptului că este un algoritm util în optimizarea proiectării bazelor de date distribuite orientate-obiect fragmentate vertical la care nu trebuie precizat de la început numărul total de partiții. În această lucrare am subliniat faptul că este o adaptare a algoritmului din lucrarea anterioară, de la bazele de date distribuite relaționale la bazele de date distribuite orientate-obiect. Acest studiu a fost prezentat și publicat la Conferința 9th International Carpathian Control Conference - ICCC 2008, Sinaia, ISBN 978-973-746-897-0.

Anexele cuprind schema bazei de date distribuită folosită ca exemplificare de-a lungul întregii teze, urmată de structura bazei de date folosită în experimente, cât și structura tabelelor componente și de codurile sursă ale algoritmilor implementați în limbajul C++.

În această teză, am prezentat o abordare generală a partitioanării verticale de datelor. Acest studiu evidențiază posibilitatea utilizării matricii de afinitate a atributelor în algoritmii de partitioanare. Folosirea unei funcții obiective de la metodele de grupare (clustering) la algoritmii de partitioanare este prezentată printr-o implementare eficientă. Utilizând acest algoritm se pot evalua și verifica alți algoritmi de partitioanare verticală care folosesc ca dată de intrare matricea de utilizare a atributelor. Astfel se pot dezvolta algoritmi euristici care să ofere posibilitatea de a folosi această funcție obiectiv de evaluare. Acest algoritm poate modificat ușor pentru include și alte informații preluate de la proiectantul bazei de date, cum ar tipurile de tranzacții (de acces la date sau de actualizare a datelor), informații referitoare la alocarea datelor și costurile de transmisii de date.

Mi-am propus să dezvolt ulterior și alți algoritmi euristici pe baza acestei abordări propuse în lucrare și să pot integra un astfel de algoritm într-o aplicație mai complexă care să ajute proiectantul bazei de date distribuite să aleagă o modalitate corectă și cât mai eficientă de implementare a informațiilor gestionate cu ajutorul unei baze de date distribuite.