

CONTROLUL ACCESELOR CONCURENTE LA BAZE DE DATE

Introducere.

Sistemele de programe care realizează controlul concurenței sunt cea parte a sistemului de gestiune a bazei de date (SGBD), care urmărește execuția „simultană” a tranzacțiilor, astfel încât să fie produse aceleași rezultate ca și în cazul unei execuții secvențiale.

Formulând în mod diferit ideea de mai sus, putem defini controlul concurenței ca o activitate de divizare, sau distribuire a datelor conținute în baza de date, între diferiți utilizatori ai acesteia, în o astfel de manieră încât procesul acestei divizări să fie complet transparent pentru utilizatori.

O soluție primitivă în vederea atingerii obiectivului de mai sus, ar putea fi izolarea întregii baze de date în timpul execuției- sau prelucrării- fiecărei tranzacții, izolarea fiind realizată de către SGBD. Această modalitate de control este simplă, dar neeficientă. Performanțele unui sistem de baze de date ce folosește un astfel de mod de prelucrare se vor deteriora repede, până la un nivel inacceptabil, odată cu creșterea numărului utilizatorilor bazei de date. Drept consecință, proiectanții de sisteme de gestiune au căutat să elaboreze algoritmi simpli, care să asigure un grad înalt de concurență, odată cu realizarea unor performanțe acceptabile.

În cele de mai sus, au fost folosite concepte generale care nu au fost încă definite în mod specific, în contextul tematic abordat. Acestor concepte le corespund termenii de concurență a acceselor, tranzacție, performanțe. Pe parcursul paragrafelor următoare, acești termeni vor fi definiți în o manieră mai specifică.

Integritatea datelor

Integritatea datelor este reprezentată de concordanța acestora cu proprietățile sistemelor din lumea reală pe care le modelează. Respectarea integrității datelor este o problemă esențială în cazul bazelor de date la care au loc accese concurente.

Schema unei baze de date conține descrierea datelor și, implicit, „**restricțiile de integritate**” cărora trebuie să se supună aceste date.

Restricțiile de integritate este o aserțiune care trebuie să fie respectată, sau verificată, de către date în anumite momente determinate.

O bază de date este coerentă dacă datele pe care le conține respectă ansamblul restricțiilor de integritate implicită sau explicită ce au fost definite în contextul definirii bazei de date.

Pentru a aprofunda înțelegerea restricțiilor de integritate, să admitem exemplul unei baze de date de lucru formată din următoarele relații:

Cumpărare (CP, DC, CC),
Vânzare (CP; DV; CV),
Stoc (CP, CS),
Produs (CP, NP, NFU, NFA).

În schemele relațiilor, atributele au sensurile: CP- cod produs, DC- data cumpărării, CC- cantitatea cumpărată, DV- data vânzării, CV- cantitatea vândută, CS- cantitatea în stoc, NP- numele produsului, NFU- numele furnizorului, NFA- numele fabricantului.

În una din clasificările adoptate, restricțiile de integritate sunt de tipurile de mai jos:

- restricții de integritate privind un element de date. La rândul lor, acestea se pot referi la tipul de date și la domeniul de valori (de exemplu, CC este un număr întreg, iar $1 < CV < 10\,000$).
- Restricții de integritate privind mai multe elemente de date. Acestea pot fi: restricții de dependență funcțională (de exemplu, CP -> NP), restricții de dependență multi-valoare (CP ->> NFU, CP ->> NFA), restricții de dependență referențială (de exemplu, fiecare tuplu din relația Stoc trebuie să corespundă unui tuplu din relația Produs).

- c) Restricții de redundanță, care trebuie respectate de mai multe elemente de date (pentru fiecare produs, cantitatea în stoc CS trebuie să rămână egală cu diferența dintre suma cantităților cumpărate CS și suma cantităților vândute CV).
- d) Restricții ce au în vedere unii invarianti (ca exemplu, menționăm că suma generală a tuturor valorilor deținute de o bancă trebuie să rămână constantă la execuția unui transfer).
- e) Restricții temporare de integritate, respectate numai în anumite momente sau intervale de timp (de pildă, în o bancă anumite valori au o valoare determinată numai la sfârșit de lună).

Pentru exprimarea și analiza formală a restricțiilor de integritate (în afara celor temporare) se poate folosi logica predicatelor de ordinul întâi.

Tranzacții. Acțiuni.

Potrivit unei definiții larg acceptate, tranzacția este o unitate de prelucrare secvențială efectuată pentru un utilizator, care aplicată unei baze de date coerente, restituie o bază de date coerentă.

Restricțiile de integritate sunt întotdeauna invariante pentru tranzacții. În general, un sistem de baze de date execută un ansamblu de tranzacții în mod simultan, pentru diferiți utilizatori. Problemele dificile în realizarea concurenței decurg din interferențele care pot să apară între aceste tranzacții diferite, ca urmare a partajării datelor între utilizatorii bazelor de date.

Tranzacțiile sunt compuse din unități de prelucrare mai fine, ce poartă numele de acțiuni. Acțiunea este o comandă indivizibilă, executată de sistemul de gestiune în cadrul unei tranzacții. Citirea unei informații din memorie, sau înregistrarea unei informații, sunt înțelese, în general, ca acțiuni.

Probleme de concurență a acceselor.

Definirea conceptelor de tranzacție și de acțiune permite punerea în lumină a unor probleme „elementare” ce pot să apară atunci când mai multe tranzacții încearcă să efectueze operațiuni de acces la aceleași elemente (sau obiecte) de date. Astfel de tentative conduc la situații de „**conflict**” între acțiuni, respectiv între tranzacții. Așa cum se va vedea, operațiunile respective au loc la momente de timp foarte apropiate, fără însă a fi simultane în adevăratul sens al acestui termen. În cele ce urmează, ne vom referi la două tipuri de probleme: pierderile de operație și inconsistențele.

Pierderi de operație. Un caz reprezentativ de pierdere de operație este „pierderea de actualizare”, care poate fi urmărită în Fig. 1. Așa cum se vede, o tranzacție T1 poate, în decursul efectuării unei acțiuni a_i , să citească un obiect de date într-un registru tampon de memorie (care îi aparține), urmând ca apoi să modifice valoarea acestui obiect (de exemplu, să o incrementeze cu o unitate) și să înregistreze noua valoare în memorie, în decursul unei alte acțiuni a_j ($j > i$). Este însă posibil ca o altă tranzacție T2




Fig. 1

să fi efectuat o actualizare (incrementare) a aceluiași element de date, printr-o acțiune a_k , amplasată între acțiunile a_i și a_j . Actualizarea reprezentată de acțiunea a_k , în tranzacția T2, este însă pierdută.

Inconsistențe. Mai întâi, vom trata cazul în care o tranzacție afișează conținutul unei baze de date care se găsește în stare tranzitorie. Admitem că baza de date (desigur, foarte elementară, formată

numai din elementele de date A și B) trebuie să respecte restricția de integritate $A = B$. Așa cum se vede în Fig. 2, tranzacția T2 citește A după ce acest element de date a fost modificat de tranzacția T1, respectiv citește elementul B înainte ca acesta să fi fost incrementat de T1. În acest mod, tranzacția T2 va afișa pentru A o valoare diferită de valoarea lui B.

Tranzacția T1	A=B	Tranzacția T2

Read A -> a ₁	----	
a ₁ + 1 -> a ₁	----	
Write a ₁ -> A	----	
	----	Read A -> a ₂
	----	Print a ₂
	----	Read B -> b ₂
	----	Print b ₂
Read B -> b ₁	----	
b ₁ + 1 -> b ₁	----	
Write b ₁ -> B	----	

Fig. 2

Să presupunem acum că tranzacția T2 încearcă să actualizeze baza de date atunci când aceasta este în regim tranzitoriu, respectiv se găsește într-o stare de ne-coerență, în care elementele de date nu sunt egale (A este diferit de B). Evoluția tranzacțiilor T1 și T2 este descrisă mai jos, în Fig. 3:

Tranzacția T1	A=B	Tranzacția T2

Read A -> a ₁	----	
a ₁ + 1 -> a ₁	----	
Write a ₁ -> A	----	
	----	Read A -> a ₂
	----	a ₂ x 2 -> a ₂
	----	Write a ₂ -> A
	----	Read B -> b ₂
	----	b ₂ x 2 -> b ₂
	----	Write b ₂ -> B
Read B -> b ₁	----	
b ₁ + 1 -> b ₁	----	
Write b ₁ -> B	----	

Fig. 3

Se poate observa imediat că prin aranjarea în timp de mai sus a acțiunilor tranzacțiilor T1 și T2, se obține în final o bază de date necoerentă, caracterizată prin încălcarea restricției de integritate $A=B$. În mod obișnuit, se afirmă că printr-o asemenea dispunere în timp a acțiunilor, tranzacțiile T1 și T2 se găsesc în stare de conflict, respective execuția (sau planificarea lor) implică un conflict. Este deci firesc să căutăm condițiile în care execuțiile de tranzacții sunt astfel planificate, încât să fie evitate conflictele.

Planificări fără conflict

Mai întâi, vor fi introduce câteva alte noțiuni care ocupă un loc însemnat în studiul acceselor concurente, respective al **planificării fără conflict** a execuției tranzacțiilor. Prin **“controlor”** (în literatură străină se folosesc termenii “controller” sau “scheduler”) înțelegem un modul al sistemului de gestiune a bazelor de date care urmărește și comandă accesul concurrent la informațiile conținute în o baza de date. În același context, denumim **granulă** o unitate componentă a unei baze de date, care este controlată în mod individual de un controlor.

Una din problemele care se ridică în contextul prelucrării bazelor de date în regim de concurență a acceselor este alegerea unor dimensiuni adecvate ale granulelor. Aceste dimensiuni se pot înscrie în o gamă întinsă de la lungimea unei înregistrări până la lungimea unei pagini sau a unui întreg fișier. La limită, întreaga bază de date poate reprezenta o granulă.

De dimensiunile granulelor sunt legate performanțele procesului de acces al tranzacțiilor la o bază de date. În o abordare generală, se înțelege că atunci când baza de date este divizată într-un număr mare de granule de dimensiuni mici, au acces la informație mai multe tranzacții, în acest mod realizându-se un grad mai înalt de „paralelism” în prelucrarea bazei de date. Pe de altă parte, în acest caz procesul de control al concurenței acceselor este mai complex și va reclama un interval de timp mai lung. În practică se recomandă o dimensiune variabilă a granulelor.

Datele conținute în fiecare granulă trebuie să respecte restricții de integritate care decurg din restricțiile generale acceptate pentru ansamblul bazei de date. Vom observa aici că în procesul modificării bazei de date, granulele se modifică de asemenea, ca efect al execuției unor acțiuni. Ne reamintim că acțiunile sunt unități funcționale de prelucrare secvențială, care nu trebuie să încalce restricțiile de integritate valabile pentru datele ce aparțin granulelor și, deci, respectă coerența internă a acestora.

Având în vedere elementele de mai sus, vom înțelege prin **operație** o succesiune de acțiuni care îndeplinesc o funcție bine definită asupra granulei, respectând coerența internă a acesteia. În funcție de tipul sistemului de gestiune și de modul în care sunt controlate accesele concurente, natura operațiilor poate fi diferită. În unele cazuri, operațiile sunt interpretate ele însele ca procese- sau acțiuni- indivizibile, ce efectuează prelucrări elementare (înscriri de informație, citiri, inserări etc.) asupra unor elemente de date de tipul înregistrărilor, paginilor, etc. Starea unei granule în urma efectuării unei operații, ca și unele efecte secundare la care a condus execuția operației, poartă numele de **rezultat** al operației. De pildă, rezultatul execuției unei tranzacții care prelucrează o bază de date este starea granulelor bazei de date după încheierea tranzacției, precum și conținutul eventualelor mesaje editate în urma acestui proces.

Planificarea (execuția) unei mulțimi de tranzacții.

O idee centrală avută în vedere pe parcursul considerațiilor anterioare, constă în faptul că în procesul prelucrării unei baze de date, sub controlul sistemului de gestiune, este efectuată o succesiune de acțiuni care fac parte dintr-un ansamblu de tranzacții concurente. Evident că în funcție de poziția pe care ne situăm, ca observatori, în decursul prelucrării unei baze de date, putem concepe, pregăti, urmări și controla procesul execuției tranzacțiilor concurente, sau putem analiza modul în care acest proces s-a desfășurat, după încheierea sa. Având în vedere aceste poziții, denumirile atribuite procesului prelucrării tranzacțiilor sunt diferite. În cazul prim, se folosește termenul de **planificare** sau **execuție** (în literatura străină, „schedule”), iar în cel de al doile caz- termenul de **istorie** sau chiar cel de **înregistrare** sau de **jurnal** („log”).

Fie mulțimea de tranzacții $\{ T_1, T_2, \dots, T_n \}$. Atunci, prin (T_1, T_2, \dots, T_n) putem înțelege fie succesiune a tranzacțiilor efectuate, deci o „istorie” a sistemului care prelucrează accese concurente, fie o „planificare” a viitoarei execuții concurente a acestor tranzacții.

Având în vedere execuția viitoare a tranzacțiilor, putem defini **planificarea (T_1, T_2, \dots, T_n) a acestora ca o succesiune de acțiuni, obținută printr-o intercalare a acțiunilor din compunerea tranzacțiilor T_1, T_2, \dots, T_n , respectând ordinea internă în care se găsesc aceste acțiuni în fiecare tranzacție.** Vom remarca faptul că putem înțelege în mod similar și istoria execuției

grupului de tranzacții. Așadar, **o planificare respectă cu exactitate ordinea acțiunilor fiecărei tranzacții constituate, fiind- prin definiție- secvențială.**

Pentru a ilustra considerațiunile de mai sus, fie exemplul tranzacțiilor T1 și T2, ale căror acțiuni sunt însă enumerate în ordinea lor, fără a mai fi indicată amplasarea în timp (Fig. 4):

Tranzacția T1	Tranzacția T2
Read A -> a ₁	Read A -> a ₂
a ₁ + 1 -> a ₁	a ₂ x 2 -> a ₂
Write a ₁ -> A	Write a ₂ -> A
Read B -> b ₁	Read B -> b ₂
b ₁ + 1 -> b ₁	b ₂ x 2 -> b ₂
Write b ₁ -> B	Write b ₂ -> B

Fig. 4

În descrierea dată, tranzacțiile T1 și T2 modifică elementele A și B, legate prin restricția de integritate A=B. Elementele A și B aparțin la două granule distincte, ceea ce contribuie la creșterea posibilităților de concurență. În continuare (Fig. 5 și Fig. 6), sunt prezentate două planificări posibile pentru tranzacțiile T1 și T2. PPlanificarea din Fig. 6 este inacceptabilă, deoarece conduce la o pierdere de operație.

Tranzacția T1	Tranzacția T2
Read A -> a ₁	Read A -> a ₂
a ₁ + 1 -> a ₁	a ₂ x 2 -> a ₂
Write a ₁ -> A	Write a ₂ -> A
Read B -> b ₁	Read B -> b ₂
b ₁ + 1 -> b ₁	b ₂ x 2 -> b ₂
Write b ₁ -> B	Write b ₂ -> B

Fig. 5

Tranzacția T1	Tranzacția T2
Read A -> a ₁	Read A -> a ₂
a ₁ + 1 -> a ₁	a ₂ x 2 -> a ₂
Write a ₁ -> A	Write a ₂ -> A
	Read B -> b ₂
	b ₂ x 2 -> b ₂

Read B -> b₁
b₁ + 1 -> b₁
Write b₁ -> B

Write b₂ -> B.

Fig. 6

Planificare serializabilă

Așa cum am văzut, unele planificări de tranzații conduc la pierderi de operații sau inconsistente. Un obiectiv principal al controlului concurenței acceselor este de a nu permite decât execuția acelor planificări, care nu sunt însoțite de pierderi de operație sau de inconsistente.

O soluție posibilă a problemei de mai sus poate fi execuția succesivă (serială) a tranzațiilor. Prin adoptarea unei asemenea planificare se poate evita complet apariția pierderilor de operație și inconsistențelor, efectuarea acțiunilor ce compun fiecare tranzație desfășurându-se separat și independent de evoluția altor tranzații, fără intercalarea în timp a acestor acțiuni. Execuția serială a unui grup de tranzații poartă numele de **succesiune**.

Drept consecință a considerentelor expuse, rezultă că în scopul excluderii posibilității de conflict între acțiunile tranzațiilor, trebuie permise numai acele planificări care conduc la aceleași rezultate ca cele date de o succesiune, pentru fiecare dintre tranzații. Planificările de acest tip se numesc **serializabile**. Prin definiție, o planificare a tranzațiilor (T₁, T₂,, T_n) este serializabilă, dacă pentru fiecare tranzație participantă ea conduce la aceleași rezultate ca o succesiune a tranzațiilor (T₁, T₂,, T_n).

Prin urmare, din punctul de vedere al controlului concurenței acceselor diferitelor tranzații la informațiile conținute în o baza de date, sarcina sistemelor de gestiune (fie ele centralizate sau distribuite) este de a genera numai planificări serializabile. În acest mod, este asigurată absența conflictelor între acțiunile tranzațiilor. Pentru realizarea acestui deziderat, operațiile din care este compusă execuția tranzațiilor trebuie să posede proprietăți specifice.

Proprietăți ale operațiilor.

Vom distinge două clase de operații care, prin proprietățile lor, pot asigura serializabilitatea planificării tranzațiilor: operații compatibile și operații permutabile.

Înainte de a defini operațiile compatibile, vom observa că două operații ce fac parte din tranzații diferite și care nu efectuează modificări în nicio entitate, pot fi întotdeauna executate simultan, fără a interveni schimbări reciproce asupra rezultatelor lor. Cu alte cuvinte, de exemplu, orice fel de intercalare de operații care nu fac decât citiri, conduce la rezultate identice în cazul unei execuții succesive a operațiilor.

Prin definiție, operațiile O₁ și O₂ sunt **compatibile** dacă și numai dacă, oricare ar fi execuția lor simultană, rezultatul acesteia este același cu cel al execuției secvențiale (seriale) a operației O₁ urmată de operația O₂, sau a operației O₂ urmată de O₁. Remarcăm faptul că rezultatele execuțiilor O₁ urmată de O₂, respectiv O₂ urmată de O₁, pot fi diferite.

Pentru aprofundarea considerenților prezenți pot fi folosite exemplele din Fig. 7, în care operațiile O₁₁ și O₂₁ sunt compatibile, pe când O₂₁ și O₂₂, respectiv O₁₃ și O₂₃ nu sunt compatibile.

O11 Read A -> a₁
 a₁ x 2 -> a₁
 Print a₁

O21 Read A -> a₂
 a₂ + 1 -> a₂
 Print a₂

O12 Read A -> a₁
 a₁ x 2 -> a₁
 Write a₁ -> A

O22 Read A -> a₂
 a₂ + 1 -> a₂
 Write a₂ -> A

O13 Read A $\rightarrow a_1$
 $a_1 + 1 \rightarrow a_1$
 Write $a_1 \rightarrow A$

O23 Read A $\rightarrow a_2$
 $a_2 + 10 \rightarrow a_2$
 Write $a_2 \rightarrow A$

Fig. 7

Este evident că operațiile care prelucrează granule diferite sunt întotdeauna compatibile, întrucât pentru un asemenea caz nu pot surveni pierderi de operație dacă operațiile se intercalează. Se înțelege că atunci când există posibilitatea de intercalare prin care se generează o pierdere de operație, operațiile implicate nu vor fi compatibile.

Ordinea în care pot fi executate operațiile și rezultatele acestei execuții determină o altă proprietate importantă a unor clase de operații. Să începem prin a remarca faptul că, în unele situații, rezultatele unei execuții de operații poate depinde de ordinea în care aceasta este realizată. Pe de altă parte, în alte cazuri ordinea poate fi indiferentă. În același context, să mai observăm că proprietatea de compatibilitate a operațiilor este independentă de ordinea acestora.

Vom defini două operații O1 și O2 ca fiind **permutabile**, dacă și numai dacă orice execuție a acestor operații în ordinea O1, O2 conduce la același rezultat cu execuția în ordinea O2, O1. Revenind la Fig. 7, operațiile O13 și O23 sunt permutabile, în timp ce O12 și O22 nu sunt permutabile. Sunt întotdeauna permutabile două operații care prelucrează granule diferite, execuția uneia din aceste operații neputând schimba rezultatul execuției celei de a doua operații și invers.

Compatibilitate, permutabilitate, serializabilitate

În cele ce urmează, va fi pusă în lumină dependența proprietății de serializabilitate a unei execuții de tranzacții, de proprietățile de compatibilitate și permutabilitate ale operațiilor care compun tranzacțiile.

Mai întâi, subliniem două transformări de bază la care pot fi supuse planificările de tranzacții:

-separarea operațiilor compatibile O1 și O2 executate de două tranzacții diferite, constă în înlocuirea execuției simultane $E(O1, O2)$ a acestora, printr-o secvență care conduce la același rezultat, respectiv $(O1, O2)$, sau $(O2, O1)$. Așadar, procesul de separare permite aranjarea în succesiune a operațiilor compatibile executate de către tranzacții diferite.

-Permutarea operațiilor permutabile O1 și O2, executate de două tranzacții diferite, constă în schimbarea ordinei de execuție a acestor operații (de pildă, secvența $(O1, O2)$ este înlocuită cu secvența $(O2, O1)$).

Luând în considerare cele două transformări definte anterior, rezultă că o **condiție suficientă pentru ca o planificare de tranzacții să fie serializabilă este ca prin separarea operațiilor compatibile și prin permutarea operațiilor permutabile, planificarea să fie transformată în o succesiune de tranzacții componente.**

Pentru a ilustra considerațiunile prezentate, să examinăm exemplul planificării din Fig. 5. Dacă ne oprim numai asupra operațiilor, planificarea poate fi reprezentată în forma:

T1 : $A + 1 \rightarrow A$
T2 : $A \times 2 \rightarrow A$
T1 : $B + 1 \rightarrow B$
T2 : $B \times 2 \rightarrow B$.

Operațiile $A \times 2 \rightarrow A$ și $B + 1 \rightarrow B$ sunt permutabile, deoarece lucrează asupra unor granule diferite. În consecință, planificarea poate fi transformată în următoarea:

T1 : $A + 1 \rightarrow A$
T1 : $B + 1 \rightarrow B$

T2 : A x 2 -> A

T2 : B x 2 -> B.

Noua planificare obținută este o succesiune de tranzacții, respectiv tranzacția T1 urmată de tranzacția T2. Ca urmare, planificarea reprezentată în Fig. 5 este serializabilă.

Grafuri de precedență.

Vom defini mai întâi noțiunea de precedență, pentru orice planificare ce nu conține operații simultane (spre exemplu, planificări obținute prin separare de operații compatibile). În acest scop, să admitem că P este o planificare ce nu conține operații simultane. Pein definiție, afirmăm că în planificarea P are loc **precedența tranzacției T1 față de tranzacția T2** (adică T1 precede T2, cu notația $T1 < T2$), dacă și numai dacă există două operații nepermutabile O1 și O2, astfel încât operația O1 este executată de tranzacția T1 înainte ca operația O2 să fie executată de tranzacția T2.

Pentru a descrie interacțiunile dintre tranzacții în timpul unei execuții poate fi folosit **graful de precedență**. În graful de precedență al unei planificări se asociază un nod cu fiecare tranzacție, între nodurile T1 și T2 fiind trasat un arc orientat de la nodul T1 la nodul T2 dacă și numai dacă tranzacția T1 precede tranzacția T2. Potrivit unei teoreme specifice, pe care nu o demonstrăm aici, o condiție suficientă ca o planificare de tranzacții să fie serializabilă este ca graful de precedență asociat cu planificarea să nu conțină contururi închise sau bucle proprii.

Pentru exemplificare, în Fig. 8 este prezentat graful de precedență al planificării din Fig. 5. În graf nu avem contururi închise, deci planificarea este serializabilă.

T1

T2

Fig. 8

Un alt exemplu, cel următor, se referă la planificarea din Fig. 9, care nu este serializabilă.

T1 : A + 1 -> A

T2 : A x 2 -> A

T2 : B x 2 -> B

T1 : B+ 1 -> B

T1

T2

Așa cum se vede, graful de precedență al planificării – reprezentat în aceeași figură- are un contur închis, fapt care potrivit teoremei enunțate confirmă ne-serializabilitatea planificării propuse.