Corso
di
Basi di Dati Spaziali

La progettazione fisica: gli indici spaziali - 2

Angelo Montanari
Donatella Gubiani

Indici data-driven

- Gli indici data-driven si adattano alla distribuzione degli oggetti (rettangoli) sul piano
- Ad ogni nodo è associato un rettangolo, detto *Directory Rectangle* (DR), che rappresenta l'MBB dei rettangoli dei nodi figli (o degli oggetti ad esso associati)
- Per accedere ad un rettangolo della collezione indicizzata, si percorre l'albero dalla radice verso una o più foglie, verificando, per ogni Directory Rectangle incontrato, le relazioni di sovrapposizione o di inclusione

Tipologie di indici

- La struttura originaria
  R-alberi
- Diverse varianti, tra le quali
  R*-alberi
  R^+-alberi

R-alberi

- Sono una estensione multidimensionale dei B^+-alberi (struttura ad albero bilanciata e paginata)
- Ogni nodo rappresenta un rettangolo. I nodi sono organizzati in base alla relazione di inclusione:
  - ogni nodo foglia contiene un vettore di entry [MBB,OID] e rappresenta un contenitore di oggetti
  - ogni nodo interno contiene un vettore di entry [DR,NODEID] e rappresenta la più piccola area rettangolare (MBB) che contiene gli oggetti rappresentati dai corrispondenti nodi figli

Struttura dell'R-albero

- per ogni nodo dell'albero, ad eccezione della radice, il numero di entry è compreso fra m ed M con m ∈ [0,M/2]
- ogni nodo interno N contiene entry della forma [DR,NODEID], dove DR è un Directory Rectangle di un nodo figlio di N e NODEID è l'indirizzo della pagina corrispondente
- ogni nodo foglia N contiene entry della forma [MBB,OID], dove MBB è un minimal bounding box della geometria dell'oggetto memorizzato all'indirizzo OID
- la radice ha almeno due entry
- tutte le foglie si trovano alla stessa profondità

Regioni: clipping vs. overlapping

- Dato un poligono, gli R-alberi assegnano tale poligono ad una regione in base alla tecnica di *overlapping* delle regioni
- A differenza di quanto accade nei metodi space-driven, un poligono è assegnato ad una sola regione. Le regioni dell'indice possono, però, sovrapporsi

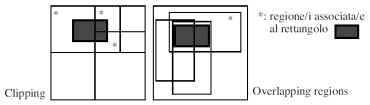

Esempio 1

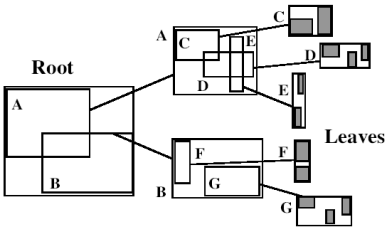

Esempio 2

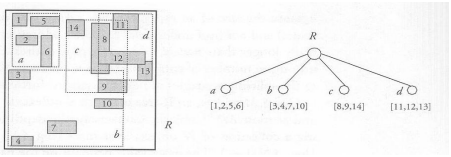

R-albero con m=2 ed M=4 (i rettangoli delle foglie sono rappresentati da linee punteggiate)

Inserimenti/cancellazioni

- Le proprietà dell'R-albero sono preservate dalle operazioni di inserimento e cancellazione
- La struttura si adatta alla distribuzione dei dati: a un gran numero di oggetti presente in una certa regione spaziale corrisponde un gran numero di foglie (vicine) dell'R-albero

Un esempio reale

- Directory rectangle delle foglie di un R-albero costruito per raccogliere i dati idrografici dello Stato del Connecticut

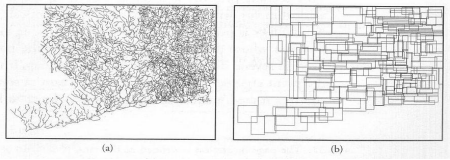

Dimensionamento di un R-albero

- Il numero massimo M di entry in un nodo dipende ovviamente dalle dimensioni dell'entry e della pagina
- Come nei B^+-alberi, M può assumere un valore diverso nei nodi interni e nei nodi foglia (OID è l'indirizzo di un record appartenente ad una data pagina ed è, di norma, più grande di NODEID, indirizzo di una pagina)
- La scelta del valore di m dipende dalle strategie di splitting dei nodi

Point query in un R-albero

- Viene eseguita in due passi:
  - PRIMO PASSO: seleziona tutti i figli della radice il cui Directory Rectangle contiene il punto P. Ripete tale operazione per tutti nodi individuati, ad ogni livello, fino a raggiungere il livello delle foglie

    In ogni nodo interno visitato N, si possono presentare due situazioni:
    - se non esiste alcuna entry il cui rettangolo contenga P, la ricerca termina (P cade nello *spazio morto* del nodo)
    - se P è contenuto nel rettangolo di una o più entry, si visita il/i corrispondente/i sottoalbero/i

Point query in un R-albero - 2

- SECONDO PASSO: l'insieme delle foglie individuate al termine del primo passo viene esaminato per stabilire se il loro MBB contiene P

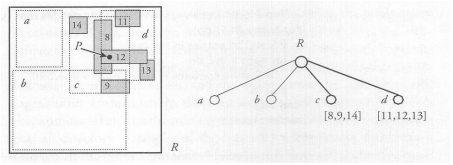

NOTA. Le window query sono molto simili alle point query (dettagli omessi)

Point query: algoritmo - 1

```
RT-POINTQUERY (P:point):set(oid)
   begin
   result = ∅
   #passo 1: attraversa l'albero dalla radice e calcola
   #SL, insieme delle foglie il cui DR contiene P
   SL = RTREETRAVERSAL(root,P)
   #passo 2: scorre le foglie e determina le entry
   #che contengono P
    for each L in SL do
        #scansione entry nella foglia L
        for each L in SL do
            if (e.mbb contains P) then result+= {e.oid}
        end for
    end for
    return result
   end
```


Point query: algoritmo - 2

```
RTREETRAVERSAL (nodeid:PageID, P:point): set of leaves
    begin
    result = ∅
    #restituisce la pagina associata al nodo
    N = READPAGE(nodeid)
    if (N is in leaf) then return {N}
    else
        #scorre le entry di N e visita quelle
        #che contengono P
        for each e in N do
            if (e.dr contains P) then
            result+= RTREETRAVERSAL(e.nodeid,P)
            end if
        end for
    end if
    return result
   end
```


Inserimento

- Gli R-alberi sono una struttura di indicizzazione dinamica gestita in modo analogo ai B^+-alberi
- Inserimento: si scende lungo l'albero scegliendo ad ogni nodo il nodo figlio corrispondente alla regione che soddisfa particolari criteri (ad esempio, minor incremento di area)
- Saturazione di una foglia: si esegue un'operazione di split che propaga le modifiche al livello superiore

Più in dettaglio.. - 1

- Per inserire un oggetto in un R-albero si attraversa l'albero a partire dalla radice fino a raggiungere una foglia (funzione INSERT)
- Ad ogni livello (nodi interni), si seleziona un nodo figlio tale che l'allargamento del suo DR necessario per contenere l'MBB dell'oggetto da inserire risulti minimo (funzione CHOOSESUBTREE); tale allargamento è nullo se l'MBB è contenuto nel DR
- Raggiunta una foglia, si possono presentare due situazioni:
  - foglia non piena: una nuova entry [MBB,OID] viene aggiunta alla pagina associata alla foglia; se il DR della foglia va allargato, bisogna propagare tale allargamento verso l'alto (funzione ADJUSTPATH). Nel caso peggiore, fino alla radice

Più in dettaglio.. - 2

- foglia l piena: deve essere effettuato uno split (funzione SPLIT). Viene creata una nuova foglia l' e le M+1 entry vanno distribuite tra l e l'. Terminato lo split, va aggiornata l'entry di l nel nodo genitore f e va inserita in f una nuova entry per l' (funzione SPLITANDADJUST). Tale inserimento può provocare lo splitting di f (se pieno). Nel caso peggiore, lo splitting può propagarsi fino alla radice incrementando di 1 la profondità dell'albero

Esempio 1

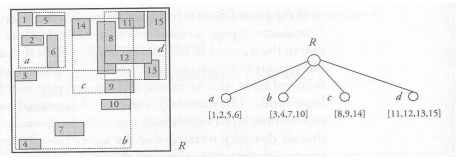

Inserimento del rettangolo 15 (assumiamo M=4)

Esempio 2

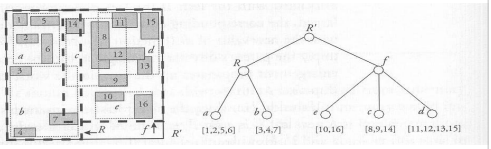

Inserimento del rettangolo 16 (16 va inserito nella foglia b che risulta essere già piena; una nuova entry va inserita anche nel genitore di b che risulta essere a sua volta già pieno..)

Insert: algoritmo

```
INSERT (e: LeafEntry)
   begin
   #inizializza la ricerca dalla radice
   node = root
   #sceglie un percorso
   while (node is not a leaf) do
         node = CHOOSESUBTREE(node,e)
   end while
   #inserisce nella foglia
   INSERTINLEAF(node,e)
   #esegui lo split e sistema l'albero se la foglia va in
   #overflow, altrimenti sistema il percorso
    if (node overflows) then SPLITANDADJUST (node)
    else ADJUSTPATH (node)
    end if
   end
```


AdjustPath: algoritmo

```
ADJUSTPATH (node: Node)
   begin
    if (node is root) then return
    else
        #trova il genitore del nodo
        parent = GETPARENT(node)
        #sistema l'entry del nodo genitore
        if (ADJUSTENTRY (parent,[node.mbb,node.id])
            then
            #entry modificata: sistema il genitore
            ADJUSTPATH (parent)
        end if
    end if
   end
```


SplitAndAdjust: algoritmo

```
SPLITANDADJUST (node: Node)
   begin
    #crea un nuovo nodo e distribuisce le entry
    new-node = SPLIT (node)
    if (node is root) then
         CREATENEWROOT (node,new-node)
    else
         #trova il genitore
         parent = GETPARENT(node)
         #sistema l'entry del nodo genitore
         ADJUSTENTRY (parent,[node.mbb,node.id])
         #inserisce il nuovo nodo nel genitore
         INSERTNODE (parent, [new-node.mbb,new-node.id])
         #sistema l'entry del nodo genitore
         if (parent overflows) then SPLITANDADJUST(parent)
         else ADJUSTPATH (parent)
         end if
    end if
   end
```


Strategie di split

- Ogni strategia che rispetti il vincolo di non avere meno di m entry per nodo è accettabile
- Requisiti fondamentali (non sempre compatibili):
  - minimizzare area (a)
  - minimizzare la sovrapposizione (b)

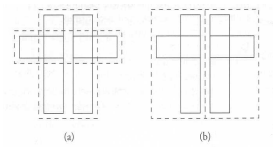

Perché ridurre l'area?

- La minimizzazione dell'area riduce gli spazi morti (si veda l'algoritmo per le point query)

Perché ridurre le sovrapposizioni?

- La presenza di regioni sovrapposte crea dei problemi nella ricerca di uno o più poligoni che contengono un punto dato
  - Non è noto a priori in quale regione dell'indice un poligono è stato inserito e bisogna, quindi, analizzare diversi sottoalberi

Cancellazioni

- La cancellazione di un'entry e da un R-albero è effettuata in 3 passi:
  - PASSO 1. Trovare la foglia L che contiene e
  - PASSO 2. Rimuovere e da L
  - PASSO 3. Riorganizzare l'albero, se necessario.

I passi 1 e 2 sono simili a passi visti in precedenza. Il passo 3 è più complicato. Soluzione semplice: cancellare il nodo e inserire nuovamente le restanti m-1 entry.

Delete: algoritmo

```
DELETE (e: LeafEntry)
  begin
   #trova la foglia contenente e
   L = FINDLEAF (e)
   #rimuove le entry e riorganizza l'albero
   #partendo da L ed e;
   #il risultato è un insieme Q di nodi
   Q = REORGANIZE (L,e)
   #reinserisce le entry nei nodi di Q
   REINSERT (Q)
  end
```

Reorganize: algoritmo

```
REORGANIZE (N:Node, e: Entry): set of node entries
   begin
   Q = ∅
   #rimuove e da N
   N = N – {e}
   if (N is not root) then
        if (|N|<m) then
           Q = Q U {N}
           #recupera il genitore e lo riorganizza
           F = GETPARENT(N)
           Q = Q U REORGANIZE(F,entry of N in F)
        else
           #N modificato: sistema il percorso
           ADJUSTPATH(N)
        end if
   end if
   return Q
   end
```


Sull'ordine di inserimento

- La qualità dell'indice dipende fortemente dall'ordine di inserimento (rettangoli distribuiti in modo random possono provocare forti sovrapposizioni di nodi e infelici collocazioni delle entry). Si veda, ad esempio, la collocazione del rettangolo 4 al passo b (spreco di spazio)

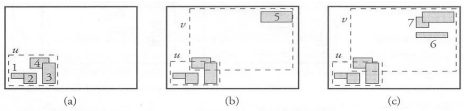

R*-alberi e Packed R-alberi

- R*-alberi e packed R-alberi costituiscono 2 tentativi di superare i limiti dell'organizzazione spaziale degli R-alberi in presenza di inserzioni random
- R*-alberi: sfruttano il reinserimento delle entry per migliorare il clustering degli MBB
- Packed R-alberi: eseguono un pre-processing di un dato insieme di rettangoli per determinare il miglior ordine di inserimento

R*-alberi

- R*-alberi realizzano diversi miglioramenti all'algoritmo di inserimento degli R-alberi
- Parametri considerati:
  - perimetro del Directory Rectangle di un nodo
  - sovrapposizione dei nodi
  - area coperta da un nodo

Miglioramento delle strategie di splitting

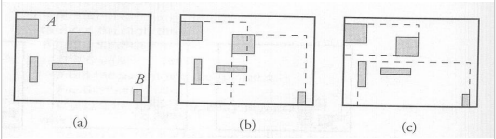

- (a) nodo in situazione di overflow; (b) split dell'R-albero (definisce la partizione a partire dalle due entry più lontane; (c) split dell'R*-albero (esegue lo split lungo uno dei due assi)

Utilizzo forzato di strategie di reinserimento

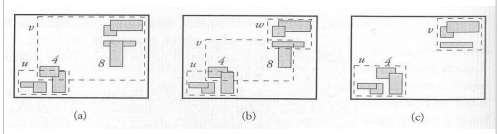

- Reinserire alcune entry ogni qualvolta si verifica un overflow in un nodo. Nell'esempio, l'inserimento di 8 causa un overflow (a). Anziché limitarsi ad una riorganizzazione locale (b), si reinserisce preliminarmente in v il nodo 4 che provoca la maggior quantità di spazio morto (c)

R-alberi vs. R*-alberi

- Confronto tra R-alberi e R*-alberi (Stato del Connecticut)

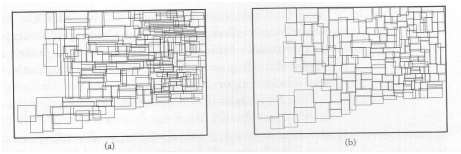

R-alberi vs. packed R-alberi

- Se la collezione dei rettangoli è stabile nel tempo, si può eseguire un pre-processing dei dati prima di creare l'R-albero (ordinare i rettangoli in base alla loro posizione per massimizzare l'occupazione dei nodi dell'R-albero)

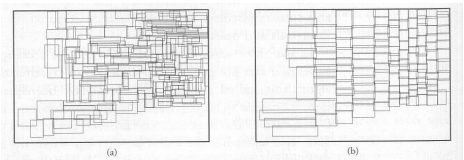

R+-alberi

- Obiettivo: ridurre i problemi che nascono dalla presenza di sovrapposizioni fra le regioni
- L'idea è quella di:
  - eseguire il *clipping* delle regioni in modo da ottenere regioni che non si sovrappongono
  - *replicare* l'associazione ad un MBR in ogni regione di livello superiore che lo contiene
- Un R+-albero occupa normalmente più spazio di un R-albero, ma tende a migliorare le prestazioni in ricerca. Richiede algoritmi più complessi per l'aggiornamento della struttura

R+-alberi: un esempio

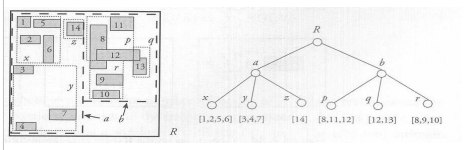

R-alberi vs. R+-alberi

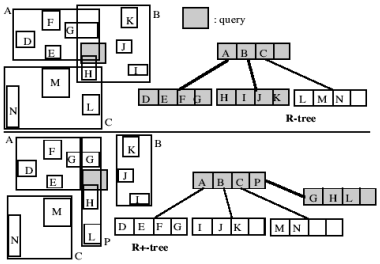

Operazioni sugli R+-alberi

- Clipping in sottorettangoli (a)
- Deadllock
- Propagazione downward di uno split

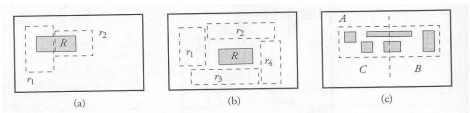

Progettazione fisica - 1

- PROBLEMA: Come suddividere e memorizzare gli insiemi di valori geometrici presenti in una base di dati geografica?
- OSSERVAZIONI:
  - Non è possibile costruire un'unica struttura dati di tipo topologico e/o un unico indice spaziale per tutti i dati contenuti nel sistema
  - Non è sempre utile costruire una struttura topologica/indice per ogni attributo di tipo POINT, LINE o POLYGON contenuto in una relazione (tabella)

Progettazione fisica - 2

- SOLUZIONE: Suddivisione della base di dati in *strati* (*layer*):
  - Per i dati del medesimo strato viene mantenuta una struttura topologica e/o indice spaziale
  - Non esiste topologia/indice tra strati diversi

Progettazione fisica - 3

- Vincoli tra Strati e Attributi con dominio geometrico in uno schema:
  - ogni strato presente in uno schema contiene solo i valori geometrici di uno o più attributi geometrici appartenenti a relazioni dello schema
  - i valori di un attributo geometrico sono contenuti in uno e un sol strato
- Da ciò deriva che:
  - in uno schema che presenti relazioni (tabelle) con attributi geometrici deve essere presente almeno uno strato
  - in uno schema che presenti relazioni (tabelle) con attributi geometrici, va indicata la corrispondenza attributo geometrico/strato

Esempio - 1

Relazioni

BOSCO (Tipo: STRING, Pg: POLYGON)
PRATO (Pascolo: BOOLEAN, Pg: POLYGON)

Strati

S_MONTAGNA ({POLYGON})

Mapping Attributi geometrici/Strati

BOSCO.Pg . S_MONTAGNA
PASCOLO.Pg . S_MONTAGNA

Esempio - 2

BOSCO

Tipo	Pg
ceduo	8
conifere	23
misto	44

PRATO

Pascolo	Pg
true	9
false	2
false	44
true	14