Ottimizzazione delle query

Leggere la sezione 8.3 di Riguzzi et al.
Sistemi Informativi

Lucidi derivati da quelli di Hector Garcia-Molina

Ottimizzazione delle query

--> Generare e confrontare i piani

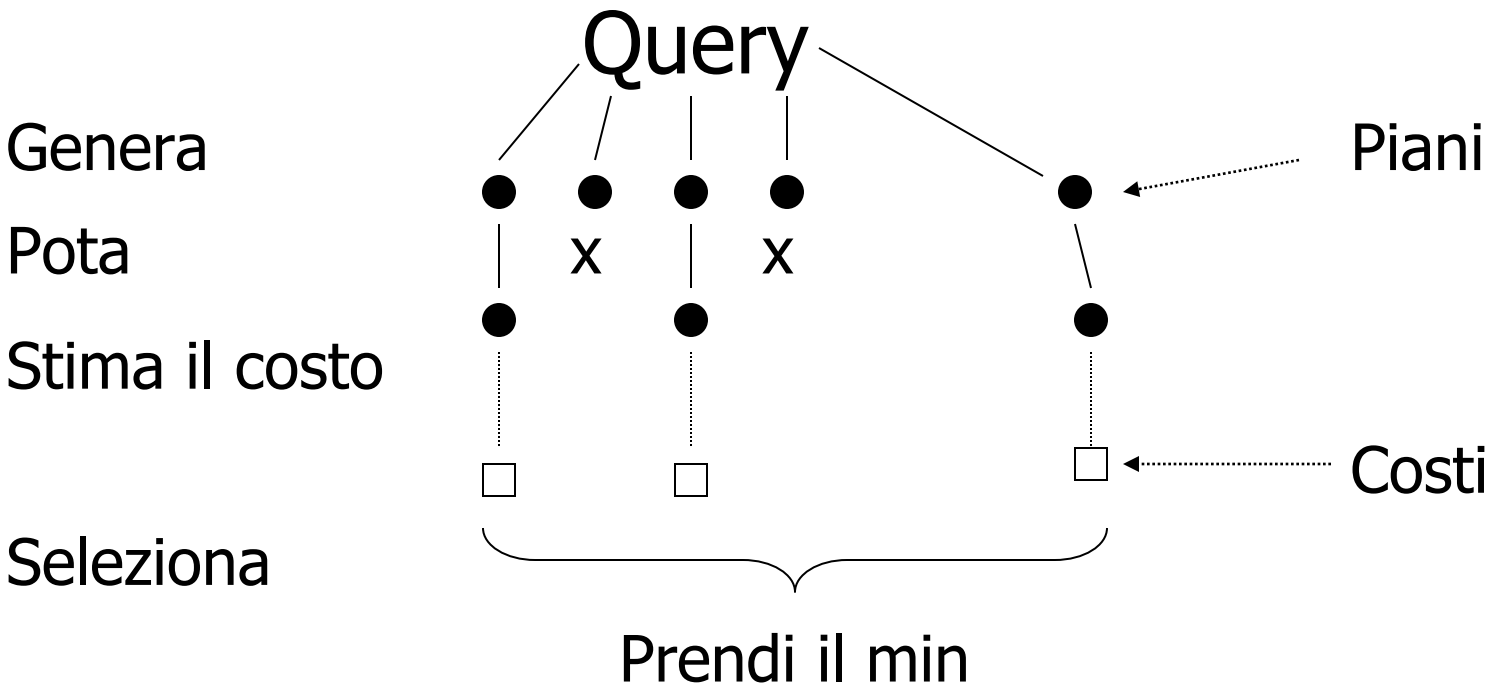

Per generare i piani si considera:

- Transformazione dell'espressione relazionale
- L'uso di indici esistenti
- Algoritmi per il join

Stima dell'IO:

- Conta il # di blocchi di disco che devono essere letti (o scritti) per eseguire il piano della query
- Parametri:
  - T(R) numero di tuple in R
  - B(R) numero di blocchi occupati da R

Indice primario

Indice su un campo sul quale il file e' ordinato

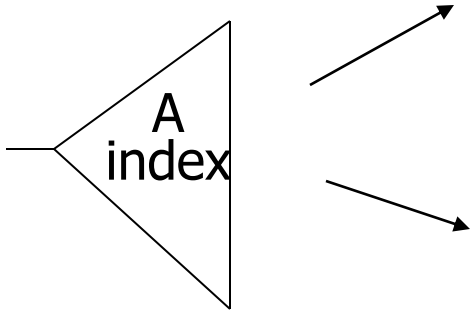

A

10	
15	
17	

19	
35	
37	

Operazioni fisiche

- Selezione
- Join

- Costo= numero di operazioni di I/O (ignorando la scrittura dell'output)

Selezione

- $\sigma_{A=a}(R)$:
  - Se non c'e' indice su A, scansione di R, costo B(R)
  - Se c'e' un indice su A, accesso tramite indice, costo $3 + \lceil B(R)/V(R,A) \rceil$ se l'indice e' primario altrimenti $3 + T(R)/V(R,A)$ (puo' essere inferiore perche' alcune tuple possono fortuitamente capitare sullo stesso blocco)

Selezione

- $\sigma_{a<chiave<b}(R)$
  - Se non c'e' un indice su A, scansione di R, costo B(R)
  - Altrimenti, sia f=(b-a+1)/(max-min+1)
    - Se l'indice e' primario, costo $3+\lceil f*B(R) \rceil$
    - Se l'indice e' secondario, costo 3+f*T(R)

Esempi

- B(R)=1.000, T(R)=20.000
- $\sigma_{A=a}(R)$
- Casi:
  - Senza indice: costo=1000
  - Se V(R,A)=100 e l'indice e' primario, costo=3+1.000/100=13
  - Se V(R,A)=100 e l'indice e' secondario, costo=3+20.000/100=203

Esempi

- Se V(R,A)=10 e l'indice e' secondario, costo=3+20.000/10=2003 => e' piu' alto della scansione!
- Se V(R,A)=20.000 cioe' A e' una chiave, allora costo=3+1=4

Join

- Vari tipi:
  - Join a un passo
  - Join a un passo e mezzo:
    - Join nested-loop basato sulle tuple
    - Join nested-loop basato sui blocchi
  - Join a due passi:
    - Sort-based join
    - Sort join
    - Index-based join
    - Hash-based join

Join a un passo

- Join di R1(A,C) con R2(C,B), R2 la piu' piccola
- R2 sta in memoria interamente

Join a un passo

- Leggi in memoria tutte le tuple di R2 e costruisci con esse una struttura in memoria centrale avente come chiave di ricerca C. Una tabella hash o un albero di ricerca vanno bene. Usa M-1 buffer per questo
- Leggi un blocco alla volta di R1 e mettilo nel rimanente buffer di memoria. Per ciascuna tupla di R1, trova le corrispondenti tuple di R2 che fanno join su C utilizzando la struttura di ricerca. Per ciascun tupla di R2 genera una tupla del risultato

Join a un passo: costo

- Costo=B(R1)+B(R2)
- Requisiti di memoria B(R2)<=M-1 o approssimativamente B(R2)<=M

Esempio R1 ⋈ R2 sull'attributo comune C

T(R1) = 10.000

T(R2) = 5.000

S(R1) = S(R2) = 1/10 di blocco

Memoria disponibile M= 501 blocchi

B(R1)=10.000x1/10=1.000

B(R2)=5.000x1/10=500

Costo=1000+500=1500

Join a un passo e mezzo

- Join nested loops o iterativo basato sulle tuple

  for each r $\in$ R1 do

    for each s $\in$ R2 do

      if r.C = s.C then output r,s pair

Esempio R1 $\bowtie$ R2 sull'attributo comune C

T(R1) = 10.000

T(R2) = 5.000

S(R1) = S(R2) = 1/10 di blocco

Memoria disponibile M= 101 blocchi

Esempio Join iterativo R1 ⋈ R2

- Abbiamo
  - T(R1) = 10,000 T(R2) = 5.000
  - S(R1) = S(R2) =1/10 blocchi
  - M=101 blocchi

Costo: per ogni tupla di R1:

[Leggi la tupla+ Leggi R2]

Totale =10.000[1+5.000]=50.010.000 IOs

Totale= T(R1)*(1+T(R2))

- Possiamo far meglio?

Usa la memoria

(1) Leggi 100 blocchi di R1

(2) Leggi tutta R2 (usando 1 blocco) + join

(3) Ripeti fino alla fine

B(R1)=1000

B(R2)=500

Costo: per ogni "pezzo" di R1:

leggi pezzo: 100 IOs

leggi R2 500 IOs

600

Totale = $\frac{1000}{100}$ x 600 = 6.000 IOs

- Possiamo fare meglio?

✉ Inverti l'ordine: R2 ⋈ R1

$$\text{Totale} = \frac{500}{100} \times (100 + 1.000) =$$

$$5 \times 1.100 = 5.500 \text{ IOs}$$

In generale

- Sia R2 la relazione piu' piccola
- Il numero di iterazioni nel loop piu' esterno e' B(R2)/(M-1) dove M e' il numero dei buffer di memoria
- Ad ogni iterazione, leggiamo M-1 blocchi di R2 e B(R1) blocchi di R1
- Il numero di I/O e' dunque

$$(B(R2)/(M-1))(M-1+B(R1))=$$
$$B(R2)+B(R1)B(R2)/(M-1)$$

In generale

- Se M, B(R1) e B(R2) sono grandi ma M e' il piu' piccolo, una approssimazione della formula e' B(R1)B(R2)/M
- Condizioni sulla memoria: M>=2

- Join nested-loop basato sui blocchi (algoritmo a un passo e mezzo)

Sort-based join (algoritmo a due passi)

(1) if R1 e R2 non sono ordinate, ordinale

(2) Merge R1 e R2. Si usano due buffer, uno per il blocco corrente di R1 e l'altro per il blocco corrente di R2. Ripeti:

(a)trova il valore minimo c di C che e' davanti nei blocchi di R1 ed R2

(b) se c non appare davanti nell'altra relazione, elimina le tuple con valore c

(c) altrimenti identifica tutte le tuple da entrambe le relazioni con valore c. Se necessario, leggi blocchi dalle relazioni ordinate R1 e R2 finche' siamo sicuri che non ci siano piu' c in nessuna relazione. M buffer sono disponibili per questo

(d) Genera tutte le tuple che possono essere formate dal join delle tuple di R1 e R2 con il valore comune c

(e) Se una delle relazioni non ha piu' tuple non considerate in memoria principale, ricarica il buffer per quella relazione

Esempio: 2 record per blocco

R1.C	R2.C
10	5
20	20
20	20
30	30
40	30
	50
	52

Esempio Sort-based Join

- Siano R1, R2 ordinate su C

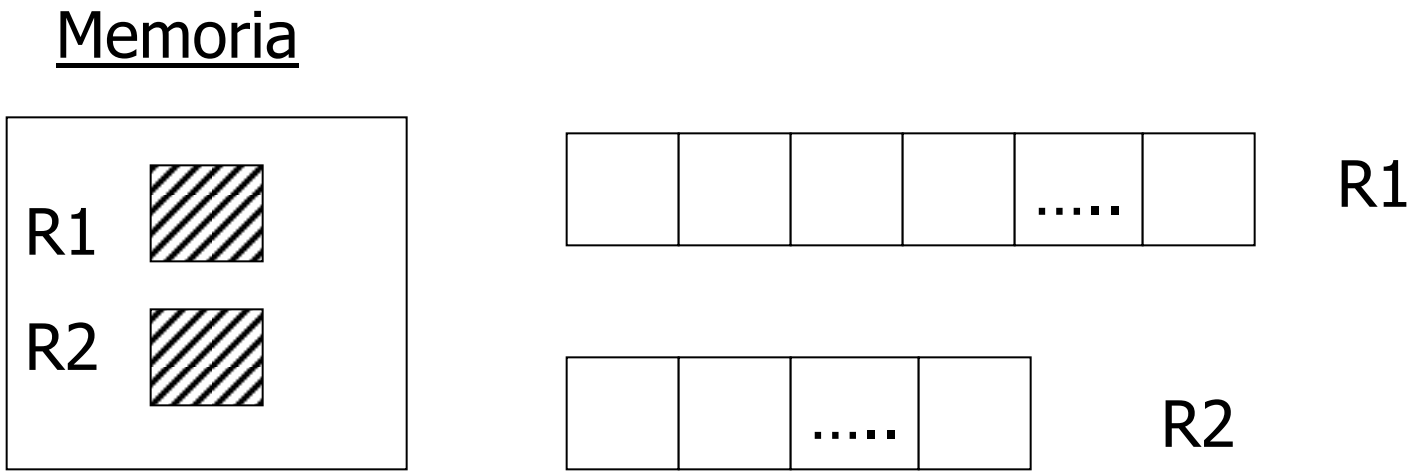

Totale: Leggi R1 + Leggi R2

= 1000 + 500 = 1,500 IOs

Esempio Sort-based Join

- R1, R2 non ordinate

--> dobbiamo prima ordinare R1, R2 …. come?

Un modo per ordinare: Merge Sort

(i) Per ciascun pezzo di R da 100 bl.:

- leggi pezzo
- ordinalo in memoria
- scrivilo su disco

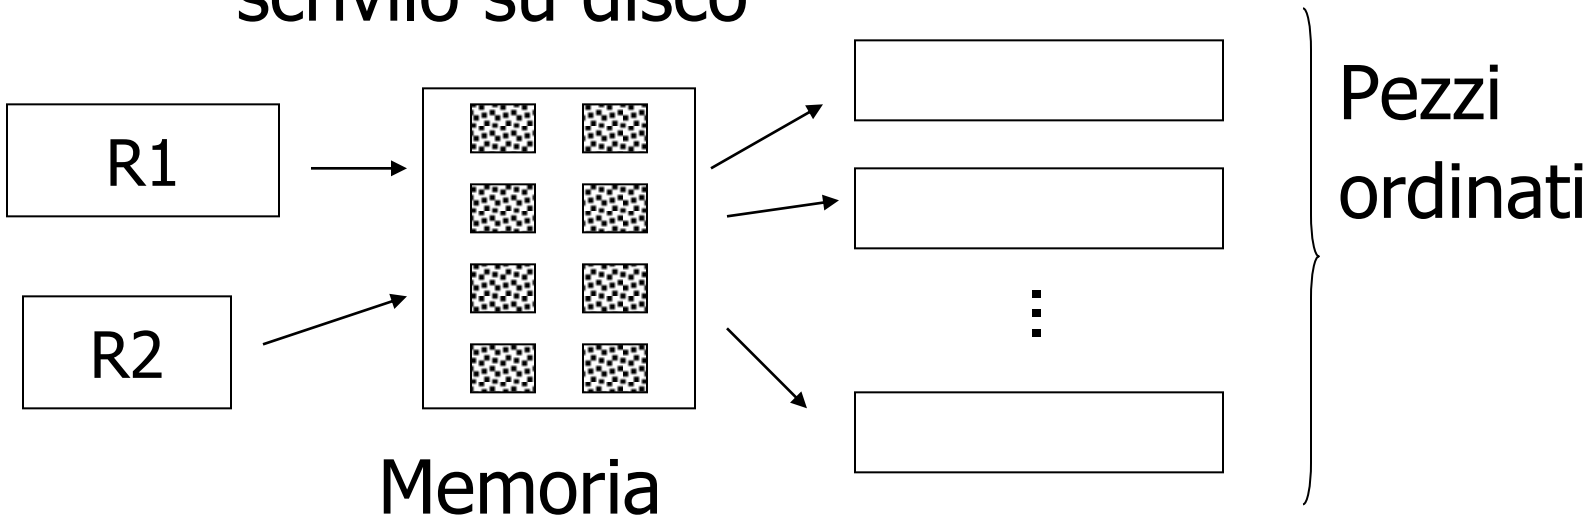

(ii) Leggi tutti i pezzi + fai il merge+ scrivi il risultato

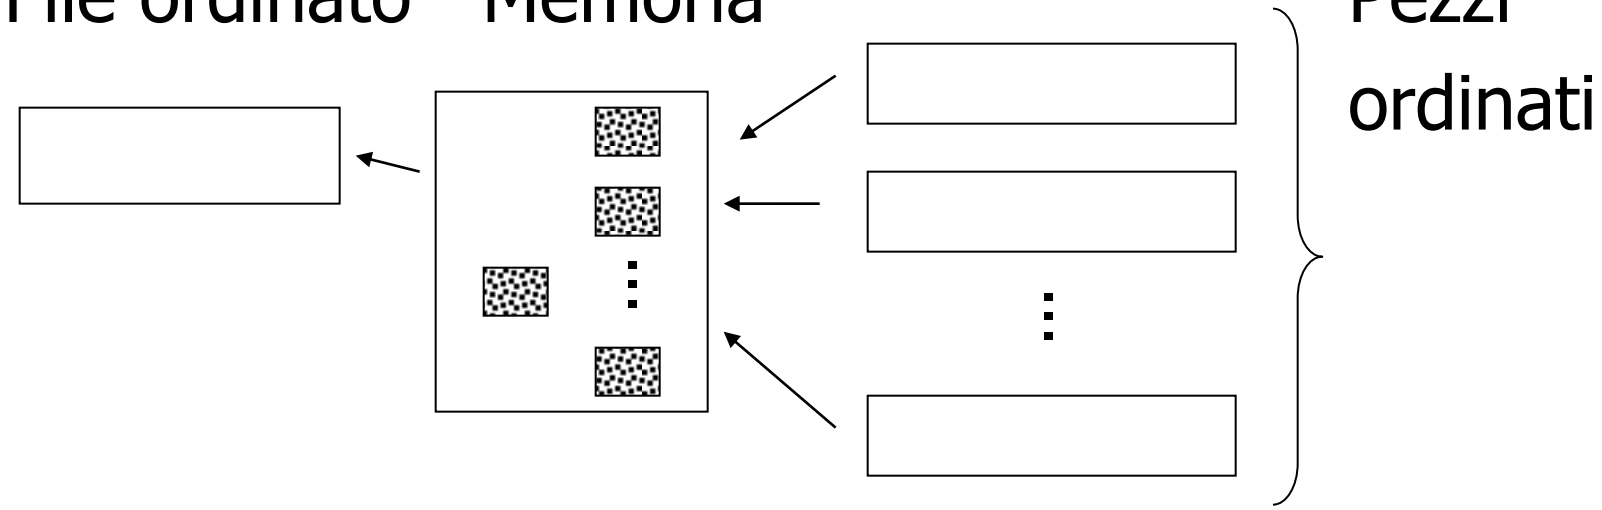

Costo: Ordinamento

Ogni tupla e' letta,scritta,

letta, scritta

quindi...

Costo del sort di R1: 4 x 1,000 = 4,000

Costo del sort di R2: 4 x 500 = 2,000

Esempio Sort-based Join (continua)

R1,R2 non ordinate

Costo totale=costo del sort+costo del join

= 6,000 + 1,500 = 7,500 IOs

Ma: costo del join iterativo= 5,500

quindi il sort-based join non guadagna!

In generale

- Costo del sort-based join: 5(B(R1)+B(R2))

Ma se R1 = 10,000 blocchi

R2 = 5,000 blocchi non ordinate

Iterativo: $\frac{5000}{100}$ x (100+10,000) = 50 x 10,100

= 505,000 IOs

Sort based join: 5(10,000+5,000) = 75,000 IOs

Sort based join vince! Il join iterativo e' infatti un algoritmo quadratico (dipende dal prodotto B(R1)B(R2))

Casi particolari

- Caso in cui le tuple con valore c per C non stanno in memoria centrale:
  - Se le tuple di una relazione con valore c stanno in M-1 buffer, allora caricale nei buffer e utilizza il rimanente per caricare le tuple dell'altra relazione
  - Se per nessuna delle due relazioni le tuple con valore c stanno in M-1 buffer, utilizza il nested loop join basato sui blocchi per queste tuple

Quanta memoria e‘ necessaria per il merge sort?

Es.: Si supponga di avere 10 blocchi di memoria, B(R1)=1.000

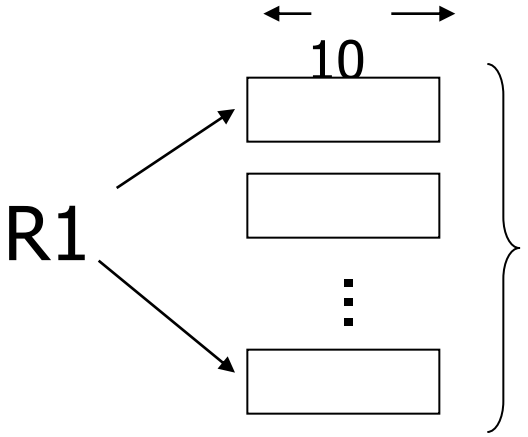

100 pezzi $\Rightarrow$ per fondere sono necessari 100 blocchi!

In generale:

Siano M i blocchi di memoria
x i blocchi della relazione

pezzi= (x/M)

dimensione del pezzo= M

pezzi $\leq$ buffers disponibili per il merge

quindi... $(x/M) \leq M-1$

o $M(M-1) \geq x$ o circa $M^2 \geq x$ o $M \geq \sqrt{x}$

per entrambe le relazioni, cioè

$M \geq \sqrt{\max\{B(R1),B(R2)\}}$

Nel nostro esempio:

R1 e' 1000 blocchi, $M \geq 31.62$

R2 e' 500 blocchi, $M \geq 22.36$

Sono necessari almeno 32 buffers

Possiamo migliorare?

Suggerimento: abbiamo bisogno dei file ordinati?

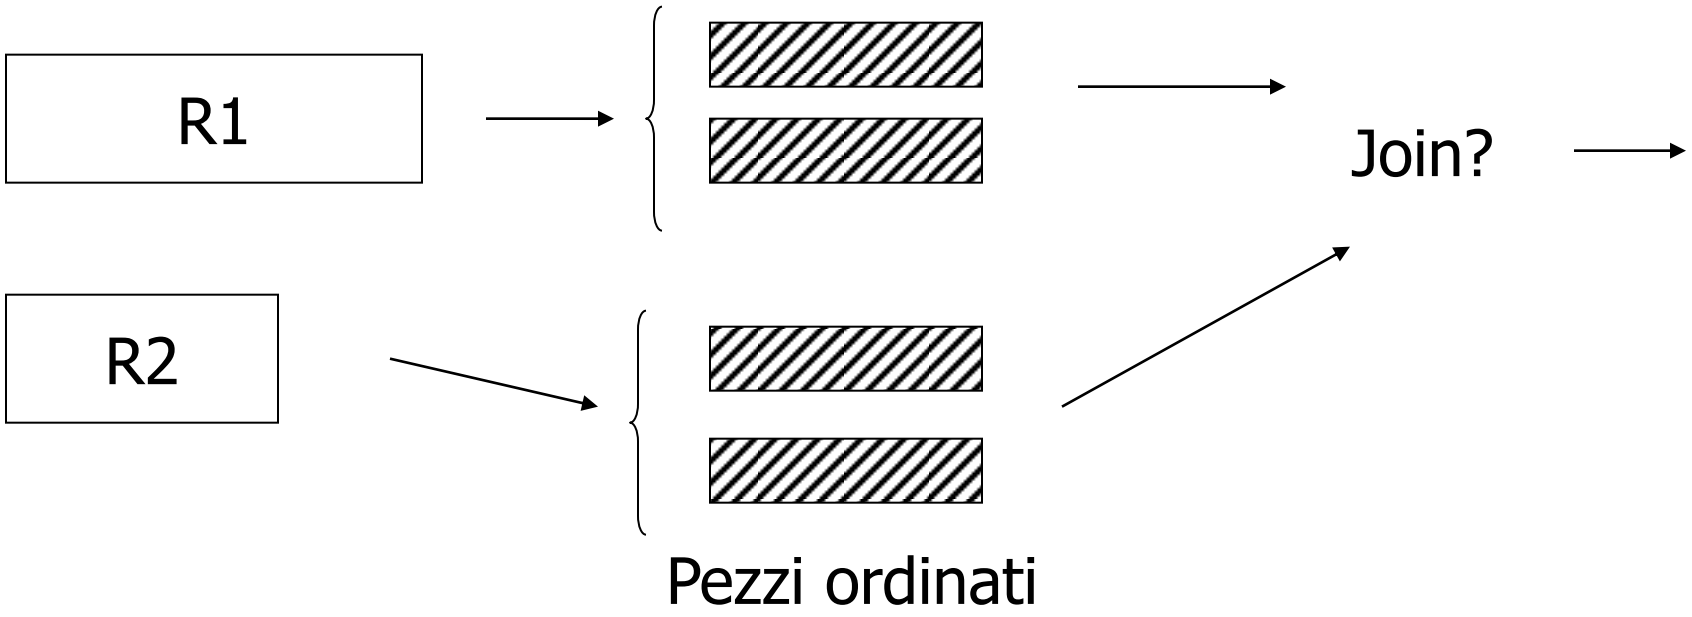

Algoritmo sort join (algoritmo a due passi)

1. Crea sottoliste ordinate su C di dimensione M per R1 ed R2
2. Porta il primo blocco di ciascuna sottolista in un buffer (si assume che ci siano meno di M sottoliste)
3. Trova il valore c di C minimo tra le sottoliste. Identifica tutte le tuple di entrambe le relazioni con C=c. Genera il join delle tuple di R1 con quelle di R2 che hanno lo stesso valore c. Se il buffer per una delle sottoliste si svuota, riempilo dal disco

Costo del sort join (sort-based join a due passi migliorato):

C = Leggi R1 + scrivi R1 in pezzi
+ leggi R2 + scrivi R2 in pezzi
+ merge dei pezzi
= 2000 + 1000 + 1500 = 4500

In generale: costo=3(B(R1)+B(R2))

→memoria necessaria? $B(R1)/M+B(R2)/M \leq M-1$
→$B(R1)+B(R2) \leq M^2$
→$M \geq \sqrt{(B(R1)+B(R2))}$

- Join con indice (concettualmente)

Si assuma un indice su R1.C

For each r $\in$ R2 do

[X $\leftarrow$ index (R1, C, r.C)

for each s $\in$ X do

output r,s pair]

Nota: X $\leftarrow$ index(rel, attr, value)

=> X = insieme di tuple di rel con attr = value

Esempio Join con indice

- Si assuma che esista l'indice R1.C a 2 livelli
- Si assuma R2 non ordinata

- Si assuma che l'indice di R1.C stia nella memoria

Costo:

per ciascun tupla di R2:

- testa l'indice (gratis)
- leggi le tuple di R1

Costo dell'index join

- Costo per reperire le tuple di R2: B(R2)
- Costo per reperire le tuple di R1:
  - Se l'indice e' primario:
    - T(R2)⌈B(R1)/V(R1,C)⌉
  - Se l'indice e' secondario
    - T(R2)T(R1)/V(R1,C)

Costo totale con il join con indice

V(R1,C) = 5000

(a) Indice primario =
500+5.000x⌈(1.000/5.000)⌉ =
500+5000x1=5.500

(b) Indice secondario =
500+5.000x10.000/5.000=500+5.000x2
=10.500

Cosa succede se l'indice non sta in memoria?

Esempio: si supponga che l'indice su R1.C sia 201 blocchi

- Mantieni la radice + 99 nodi foglia in memoria
- Il costo atteso di ciascun test e'

$$E = (0)\frac{99}{200} + (1)\frac{101}{200} \approx 0.5$$

Costo totale (inclusi i test, indice secondario)

= 500+5000 [test+ ottieni records]

= 500+5000 [0.5+2]

= 500+12,500 = 13,000

Costi e requisiti

- Join con indice primario
  - Costo = B(R2)+T(R2)⌈B(R1)/V(R1,C)⌉
  - Blocchi necessari=2
- Join con indice secondario
  - Costo = B(R2)+T(R2)T(R1)/V(R1,C)
  - Blocchi necessari=2

Fin qui

$R2 \bowtie R1$

Nested-loop basato sui blocchi	5500
Sort-based Join (rel ord)	1500
Sort-based Join	7500
Sort-Join	4500
Join con indice primario	5500
Join con indice secondario	10500

Considerazioni

- Sembra che l'index join non convenga
- In realta', se R2 e' molto piccola rispetto a R1 e V(R1,C) e' grande, la maggior parte di R1 non verra' mai esaminata dall'algoritmo mentre il sort join, l'hash join e il nested loop esaminano ogni tupla di R1 almeno una volta

- Hash join (algoritmo a due passi)
  Funzione hash h, range $0 \rightarrow k$
  - Buckets per R1: G0, G1, ... Gk
  - Buckets per R2: H0, H1, ... Hk

Algoritmo

(1) Manda le tuple di R1 nei bucket G

(2) Manda le tuple di R2 nei bucket H

(3) For i = 0 to k do

unisci le tuple nei bucket Gi, Hi

Semplice esempio hash: pari/dispari

R1	R2
2	5
4	4
3	12
5	3
8	13
9	8
	11
	14

Buckets

	R1	R2
Pari	2 4 8	4 12 8 14
Dispari	3 5 9	5 3 13 11

Esempio Hash Join

- R1, R2 non ordinate, M=101

→ Usa 100 buckets, un blocco per bucket

→ Leggi R1, hash, + scrivi i buckets

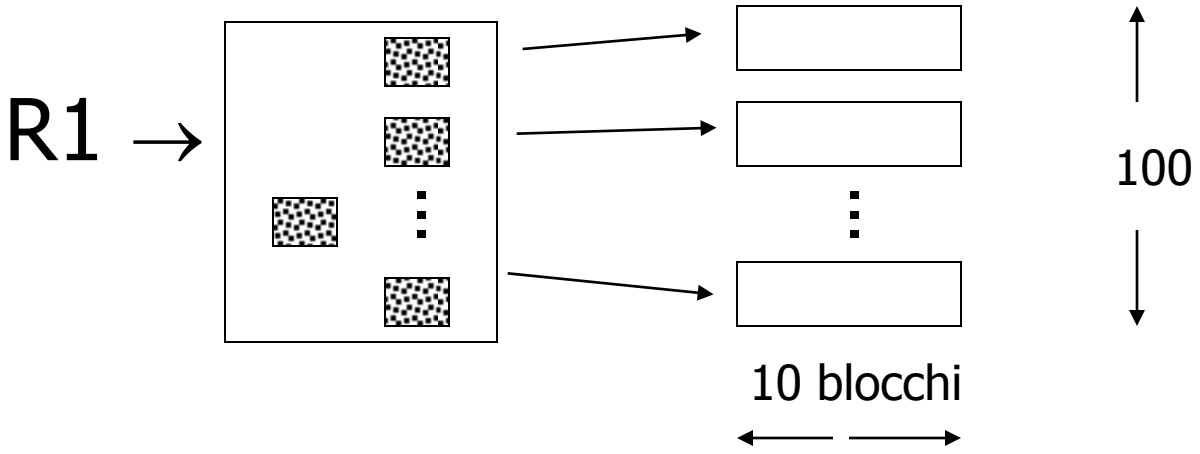

-> Lo stesso per R2

-> Leggi un bucket di R2; costruisci una tabella hash in memoria

-> Leggi il corrispondente bucket di R1 un blocco alla volta + reperisci le tuple di R2 corrisp. con la funzione hash

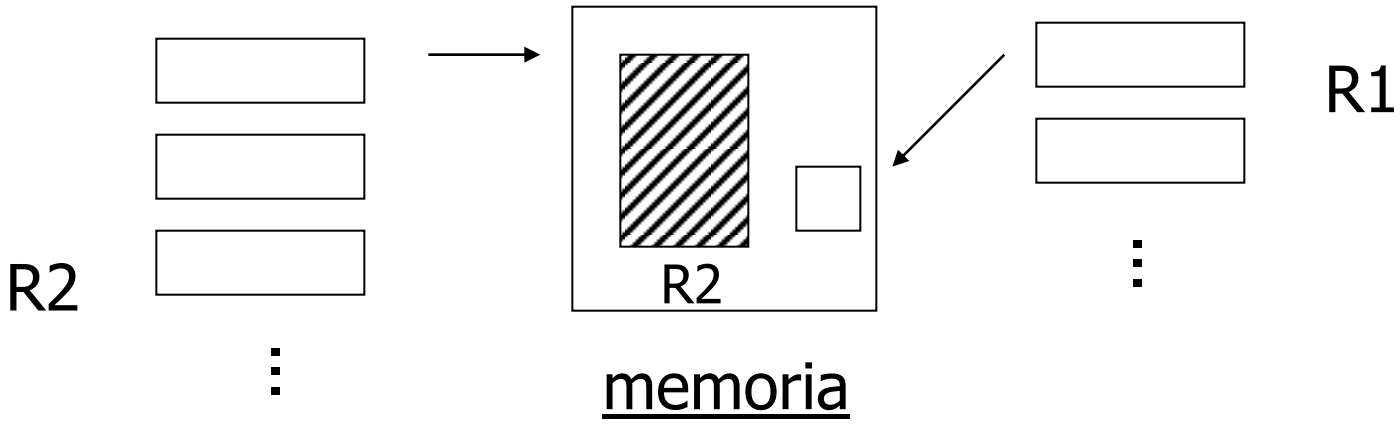

Ripeti per tutti i buckets

Costo:

"Bucketizza:" Leggi R1 + scrivi

Leggi R2 + scrivi

Join: Leggi R1, R2

Costo totale= 3 x [1000+500] = 4500

In generale: costo=3x(B(R1)+B(R2))

Nota: questa e' un'approssimazione perche' i buckets variano in dimensione e dobiamo arrotondare ai blocchi

Memoria necessaria:

Se R2 è la più piccola,

dimensione del bucket di R2 =B(R2)/(M-1)

... B(R2)/(M-1) < M-1
approssimando

M > $\sqrt{}$B(R2)

Hash join ibrido

- Sia R2 la relazione piu' piccola
- Si divide R2 in k bucket
- Nel fare cio' si puo' decidere di tenere m dei k bucket interamente in memoria
  - 1 blocco per gli altri k-m bucket
- E' necessario che M sia tale che
  - mB(R2)/k+k-m<=M-1

Hash join ibrido

- Quando si leggono le tuple di R1 per suddividerle nei bucket, si tiene in memoria:
  - Gli m bucket di R2
  - Un blocco per ciascuno dei k-m bucket di R1 i cui corrispondenti blocchi di R2 furono scritti su disco
- Se una tupla t di R1 viene mandata in uno dei primi m buckets, viene immediatamente fatto il join con le tuple di R2
- Se viene mandata in uno dei k-m buckets, viene mandata nel corrispondente blocco di memoria per poi essere migrata su disco

Hash join ibrido

- Nel secondo passo, si fa il join tra i bucket corrispondenti di R1 ed R2 escluso i primi m

Esempio

Es. Numero di bucket k=12
Dimensione bucket di R2= $\lceil 500/12 \rceil$ =42 blocchi
tienine 2 in memoria (m=2)

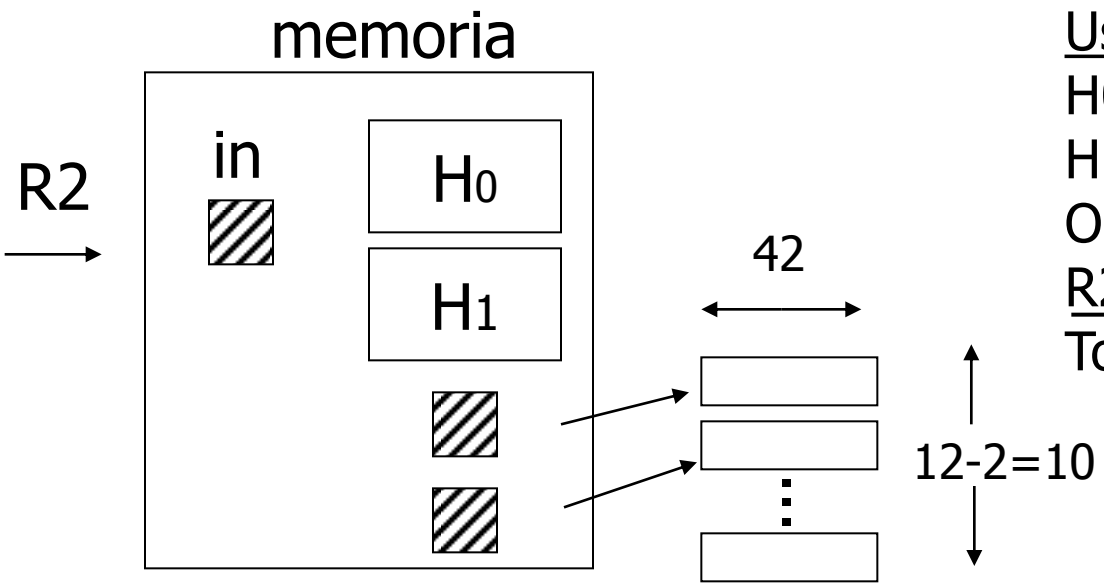

Uso della memoria:

H0	42 buffers
H1	42 buffers
Output	12-2 buffers
R2 input	1
Total	95 buffers

6 buffers inutil.!!

Poi: Bucketizza R1

- Buckets di R1 = $\lceil 1000/12 \rceil$ = 84 blocchi
- Due dei buckets di R1 uniti immediatamente con H0, H1

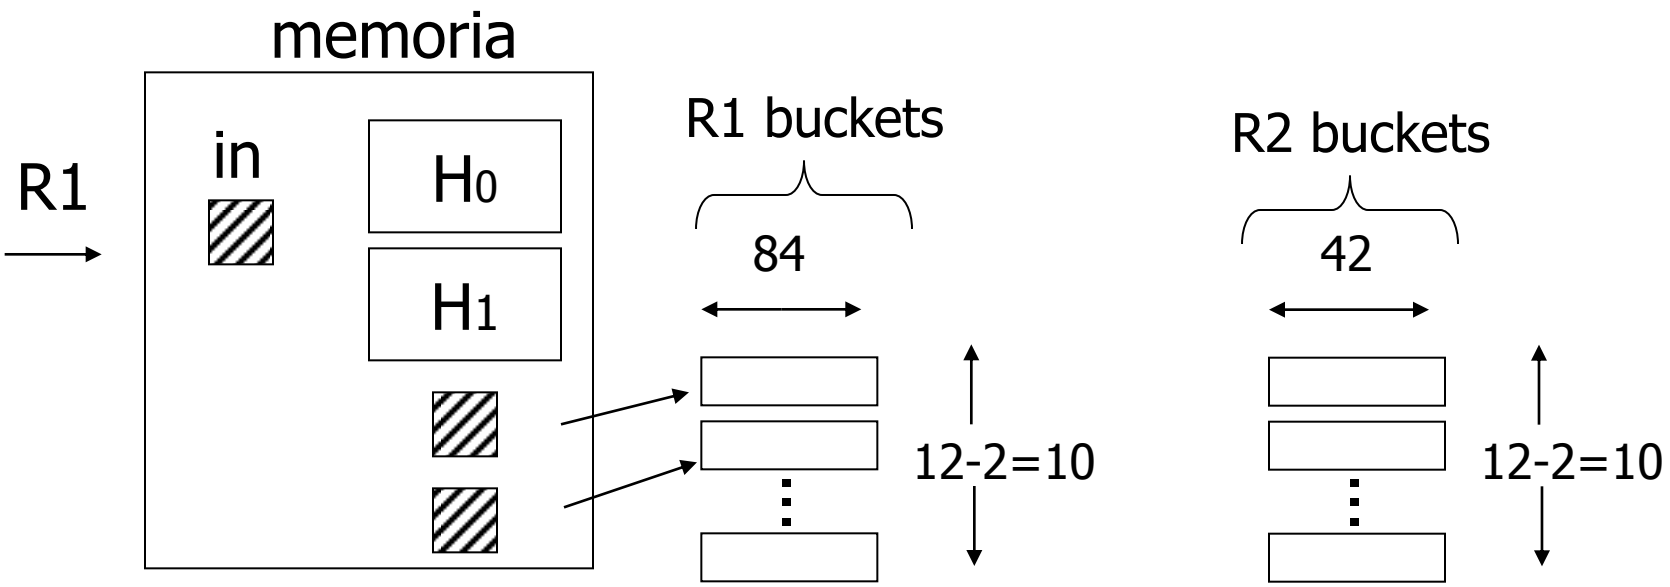

Infine: unisci i bucket rimanenti

- Per ciascun coppia di bucket:
  - Leggi uno dei bucket in memoria
  - Unisci con il secondo bucket

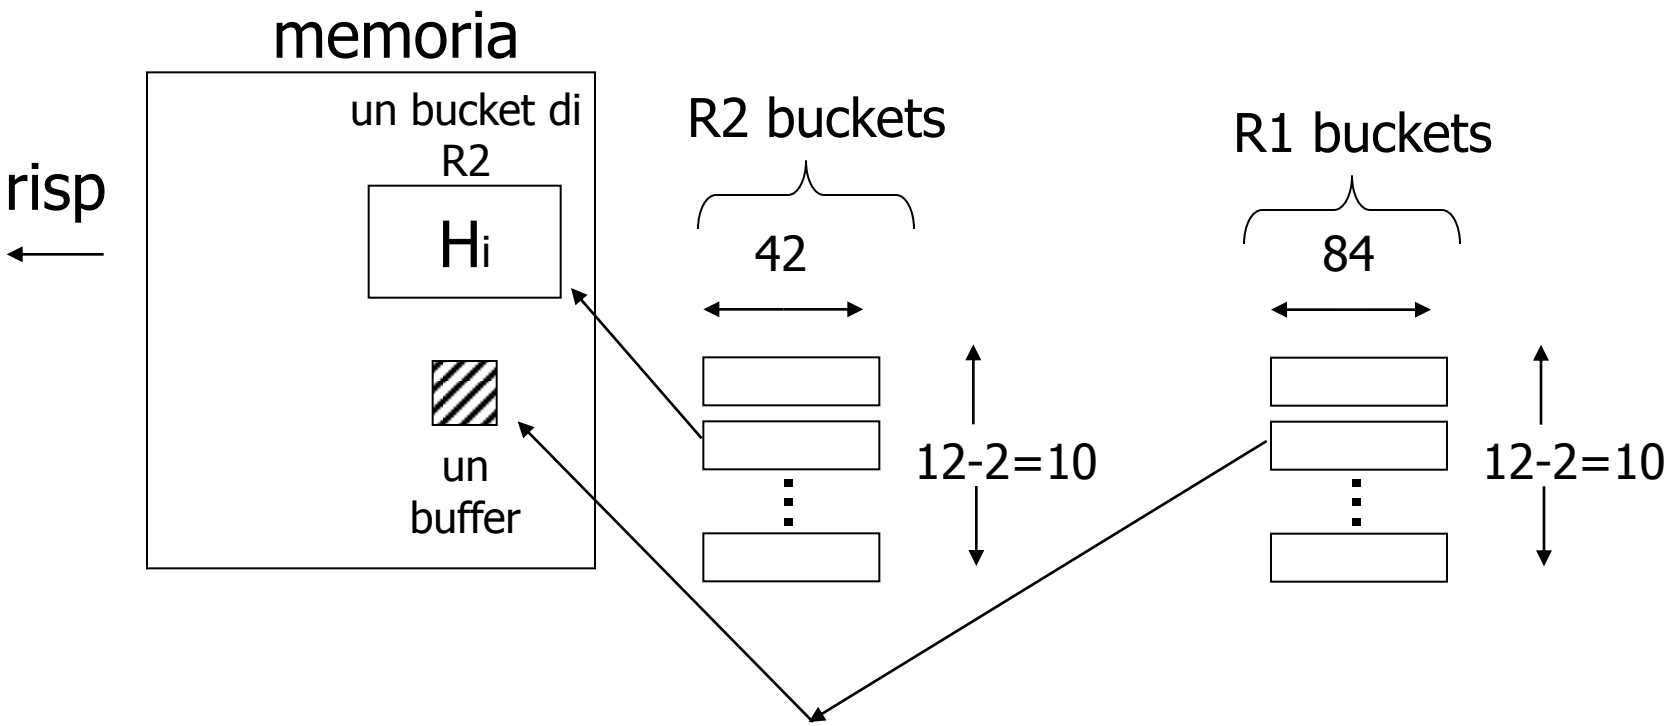

Costo

- Bucketizza R2 = 500+10×42=920
- Per bucketizzare R1, scrivi solo 10 buckets: quindi, costo = 1000+10×84=1840
- Per il join finale (2 buckets già fatti) leggi 10×42+10×84=1260

Costo totale = 920+1840+1260 = 4060

Costo dell'hash join ibrido

- Il risparmio in I/O e' due per ogni blocco dei bucket di R2 che rimangono in memoria e per i corrispondenti bucket di R1.
- Dato che m/k dei bucket sono in memoria, m/k dei blocchi rimangono in memoria e il risparmio e' 2m/k(B(R1)+B(R2))
- Quindi il costo e'

$$(3-2m/k)(B(R1)+B(R2)$$

• Quanti buckets in memoria?

Bisogna massimizzare m/k sotto il vincolo
mB(R2)/k+k-m<=M-1

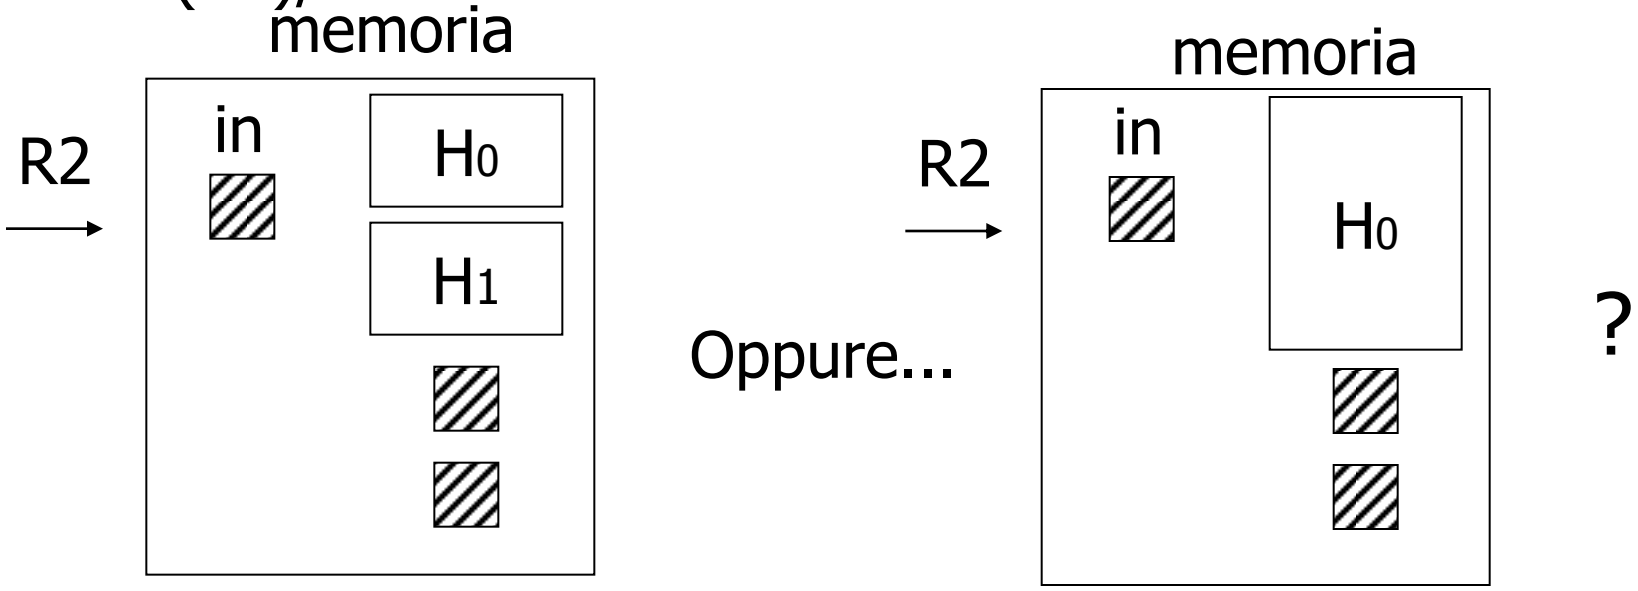

Il valore migliore si ha per m e' 1 e per k il piu' piccolo possibile

Perche'

- Tutti gli M buffer possono essere usati per tenere le tuple di R2 nella memoria tranne k-m.
- Vogliamo quindi minimizzare k
- Lo si fa' rendendo ciascun bucket grande quanto la memoria centrale
- Cioe' i buckets sono di dimensione M e $k \approx B(R2)/M$
- In questo caso, c'e' posto solo per un bucket nella memoria, cioe' m=1

Costo per il caso m=1

- In questo caso, assumendo per semplicita' che k sia circa B(R2)/M si ha

$$(3-2M/B(R2))(B(R1)+B(R2))$$

Esempio

- k=500/101=5 dimensione bucket R2 500/5=100 blocchi, non riusciamo a farli stare in memoria insieme ad altri 4 blocchi
- Scegliamo k=6
- Hashing di R2: 5 buffer per 5 buckets + $\lceil 500/6 \rceil$=84 buffer per il sesto bucket (tot 89 buffer)
- Bucket di R1= $\lceil 1000/6 \rceil$=167 blocchi
- Bucketizza R2=500+500-84=500+416
- Bucketizza R1=1000+1000-167=1000+833
- Secondo passo: 416+833=1249
- Totale=916+1833+1249=3998

Esempio

- Utilizzando la formula:

(3-2x101/500)(1000+500)=

(3-0,404)x1500=

2,596x1500=3894

Se avessimo usato

(3-2m/k)(B(R1)+B(R2))=

(3-2x1/6)1500=2,666x1500=4000

Un altro trucco dell'hash join:

- Scrivi nei bucket solo coppie
  <val,ptr>
- Quando c'e' una corrispondenza nella fase di join bisogna reperire le tuple

- Per illustrate il calcolo del costo, si assuma:
  - 100 coppie <val,ptr> /blocco
  - Numero atteso di tuple nel risultato e' 100

- Costruisci una hash table per R2 in memoria
  - 5000 tuple $\rightarrow$ 5000/100 = 50 blocchi
- Leggi R1 e unisci
- Leggi ~ 100 tuple di R2

Costo totale =	Leggi R2:	500
	Leggi R1:	1000
	Ottieni le tuple:	100
		1600

Fin qui:

Nested-loop basato sui blocchi	5500
Sort based join (rel ord)	1500
Sort based join	7500
Sort join	4500
R1.C index	5500
Hash join	
normale	4500
ibrido, R2 prima, m=2	4060
ibrido, R2 prima, m=1	3998
Hash join, puntatori	1600

Riassunto Join

Sia R2 la relazione piu' piccola, M la dim della memoria

Algoritmo	**# minimo buffer richiesti**	**# di I/O**
Join a un passo	B(R2)	B(R1)+B(R2)
Nested-loop join basato sulle tuple	1	T(R1)T(R2)
Nested-loop join basato sui blocchi	2	B(R2)+B(R1)B(R2)/M
Sort-based join	√B(R1)	5(B(R1)+B(R2))
Sort join	√(B(R1)+B(R2))	3(B(R1)+B(R2))

Riassunto join

Algoritmo	**# minimo buffer richiesti**	**# di I/O**
Join con indice primario *	2	B(R2)+T(R2)⌈B(R1)/V(R1,C)⌉
Join con indice secondario *	2	B(R2)+T(R2)T(R1)/V(R1,C)
Hash join	√B(R2)	3(B(R1)+B(R2))
Hash join ibrido	√B(R2)	(3-2M/B(R2))(B(R1)+B(R2))

* Indice interamente in memoria

Riassunto

- Iterazione ok per "piccole" relazioni (rispetto alla dimensione della memoria)
- Per l'equi-join, quando le relazioni non sono ordinate e non esiste un indice, l'hash join e' normalmente il migliore

- Sort(-based) join buono per non-equi-join (ad es., R1.C > R2.C)
- Se le relazioni sono ordinate, usa il sort-based join
- Se esiste un indice, puo' essere utile (dipende dalla stima della dimensione del risultato)