

**Basi di dati II**

**Esame — 19 settembre 2019**

Tempo a disposizione: due ore.

Cognome \_\_\_\_\_ Nome \_\_\_\_\_ Matricola \_\_\_\_\_


Basi di dati II — 19 settembre 2019

**Domanda 1** (15%)


Per ciascuno degli schedule sotto riportati, indicare, scrivendo **sì** o **no** nelle varie caselle, a quali classi appartiene: S (seriale, rispetto a letture e scritture, ignorare commit e abort), CSR (conflict-serializzabile), S2PL (generabile da uno scheduler basato su 2PL stretto), MV (generabile da uno scheduler multiversion con controllo di serializzabilità: “a serializable transaction cannot modify or lock rows changed by other transactions after the serializable transaction began”). Negli schedule,  $s_i$  indica l’inizio della transazione  $i$  e  $c_i$  il suo commit.

	S	CSR	S2PL	MV
$s_2, r_2(x), w_2(x), s_1, c_2, r_1(x), w_1(x), c_1$				
$s_1, s_2, r_1(x), r_2(x), w_2(x), r_2(y), w_2(y), c_2, r_1(y), c_1$				
$s_1, s_2, r_1(x), r_2(x), w_1(x), c_1, w_2(x), c_2$				
$s_2, r_2(x), s_1, w_2(x), r_1(x), c_2, w_1(x), c_1$				

**Domanda 2** (20%) Considerare la figura qui sotto, che schematizza una struttura con hashing estendibile, composta dalla directory, a sinistra, e dai blocchi del file, a destra, in cui sono mostrate solo le parti iniziali dei valori hash associati alle chiavi. Nel riquadro a destra, mostrare come si modifica la struttura se viene inserito un record il cui valore della funzione di hash inizia con 00111.




Mostrare poi come si modifica la stessa struttura, se, invece dell'inserimento sopra discusso, si hanno due inserimenti, di record con valori della funzione di hash che iniziano rispettivamente con 11001 e 11111.



**Domanda 3** (20%)

Considerare le relazioni R1 ed R2 e l'indice I2 su R2 schematizzati sotto. I riquadri interni indicano i blocchi e il numero a fianco a ciascun riquadro indica l'indirizzo del blocco. Nell'indice, i valori numerici sono riferimenti ai blocchi (blocchi dell'indice, per la radice e il livello intermedio, e blocchi di R2 per le foglie).



Supponendo di disporre di un buffer di **otto** pagine, considerare l'esecuzione del join di R1 ed R2, sulla base dei valori del secondo attributo di R1 e del primo di R2, con un **nested loop con accesso diretto** tramite l'indice di R2.

Indicare gli indirizzi dei blocchi su cui si eseguono operazioni di pin (o fix) per produrre le prime quattro ennuple del risultato.

Assumendo una politica di rimpiazzo *LRU*, indicare gli indirizzi dei blocchi effettivamente letti da memoria secondaria e caricati nel buffer (nell'ordine) per produrre le prime quattro ennuple del risultato.

In tal caso, indicare gli indirizzi dei blocchi che si può presumere si trovino nei buffer nel momento in cui si produce la quarta ennupla.

**Domanda 4** (15%)

Considerare un sistema distribuito con tre nodi  $N_1$ ,  $N_2$  e  $N_3$ , che eseguono due transazioni  $T_x$  e  $T_y$  che coinvolgono i tre nodi, in modo diverso. Per la prima transazione  $N_1$  è il coordinatore, mentre per la seconda il coordinatore è  $N_2$ . I due coordinatori inviano, come riportato nello schema sottostante, le richieste di **prepare**. Il nodo  $N_3$  va in crash subito dopo aver risposto alla prima richiesta (senza avere il tempo di ricevere il messaggio di **commit**) e prima di ricevere la seconda. Poi va in crash anche il nodo  $N_1$ . Indicare, nello schema sottostante, una possibile sequenza di scritture sui log e invio di messaggi (che includa anche i passi sopra illustrati), supponendo che entrambi i nodi siano ripristinati abbastanza presto (ma che vengano persi alcuni messaggi di risposta, ad esempio inviati a seguito di una decisione). Per i messaggi si usi la notazione *tipo(transaz)→destinatari* (come nell'esempio: **prepare**( $T_x$ )→ $N_2, N_3$ ). Supporre che nel log del coordinatore si scrivano solo i record di **prepare**, **commit** e **complete**, con i messaggi gestiti invece in memoria. Indicare ragionevoli istanti per i timeout, che permettano di concludere il protocollo per entrambe le transazioni.

Nodo $N_1$		Nodo $N_2$		Nodo $N_3$	
Log	Messaggi	Log	Messaggi	Log	Messaggi
<b>prep</b> ( $T_x, N_2, N_3$ )	<b>prep</b> ( $T_x$ )→ $N_2, N_3$				<i>crash</i>
	<i>crash</i>	<b>prep</b> ( $T_y, N_1, N_3$ )	<b>prep</b> ( $T_y$ )→ $N_1, N_3$		
	<i>restart</i>				<i>restart</i>

## Basi di dati II — 19 settembre 2019

**Domanda 5 (30%)** Si consideri la seguente base di dati, relativa alle ricette acquisite da un insieme di farmacie:

- Ricette(Numero, CodFarmacia, CFPaziente, Data)
- Farmacie(CodFarmacia, Nome, CodIndirizzo)
- ElementiRicetta(NumeroRicetta, CodFarmaco, Quantità)
- Farmaci(Codice, Descrizione, CodMolecola, CodCasa, Prezzo, Fascia)
- Molecole(CodMolecola, Descrizione)
- Pazienti(CF, Cognome, Nome, DataNascita, CodIndirizzo)
- CaseFarmaceutiche(CodCasa, Nome)
- ASL(Codice, Nome)
- Territorio(CodIndirizzo, Via, NumeroCivico, Comune, ASL)

Ci sono dati che cambiano nel tempo fra cui prezzi e fasce ('A', 'B' o 'C') dei farmaci e indirizzi dei pazienti.

Costruire, in tale contesto, uno schema a stella che permetta di analizzare le prescrizioni (quantità e prezzi complessivi) rispetto a

- data (dimensione standard i cui dettagli possono essere omessi);
- farmaci, con le loro proprietà (molecola e casa farmaceutica);
- prescrizione di farmaci nella stessa ricetta
- ASL di residenza e fascia d'età (ad esempio, 0-3,4-17, 18-30, ...; ma potrebbero variare) dei pazienti;
- ASL della farmacia

Supporre che, per ovvie ragioni di privacy, non possano essere riportati dati che permettano di risalire alle identità dei pazienti (CF, cognome, nome, data di nascita e indirizzo) **Indicare esplicitamente la grana dei fatti.**

Grana dei fatti:

Schema dimensionale:

## Basi di dati II — 19 settembre 2019

Descrivere, informalmente, ma in modo strutturato e comprensibile, il processo di ETL che porta alla tabella dei fatti mostrata in risposta alla domanda precedente

**Basi di dati II**

**Esame — 19 settembre 2019**

**Cenni sulle soluzioni**

Tempo a disposizione: due ore.

Cognome \_\_\_\_\_ Nome \_\_\_\_\_ Matricola \_\_\_\_\_

Basi di dati II — 19 settembre 2019



**Domanda 1** (15%)

Per ciascuno degli schedule sotto riportati, indicare, scrivendo **sì** o **no** nelle varie caselle, a quali classi appartiene: S (seriale, rispetto a letture e scritture, ignorare commit e abort), CSR (conflict-serializzabile), S2PL (generabile da uno scheduler basato su 2PL stretto), MV (generabile da uno scheduler multiversion con controllo di serializzabilità: “a serializable transaction cannot modify or lock rows changed by other transactions after the serializable transaction began”). Negli schedule,  $s_i$  indica l’inizio della transazione  $i$  e  $c_i$  il suo commit.



	S	CSR	S2PL	MV
$s_2, r_2(x), w_2(x), s_1, c_2, r_1(x), w_1(x), c_1$	sì	sì	sì	no (*)
$s_1, s_2, r_1(x), r_2(x), w_2(x), r_2(y), w_2(y), c_2, r_1(y), c_1$	no	no	no	sì
$s_1, s_2, r_1(x), r_2(x), w_1(x), c_1, w_2(x), c_2$	no	no	no	no
$s_2, r_2(x), s_1, w_2(x), r_1(x), c_2, w_1(x), c_1$	sì	sì	no	no

(\*) Postgres considera come inizio della transazione la prima operazione e non la “start”, perciò anche la risposta “sì” può essere considerata corretta

**Domanda 2** (20%) Considerare la figura qui sotto, che schematizza una struttura con hashing estendibile, composta dalla directory, a sinistra, e dai blocchi del file, a destra, in cui sono mostrate solo le parti iniziali dei valori hash associati alle chiavi. Nel riquadro a destra, mostrare come si modifica la struttura se viene inserito un record il cui valore della funzione di hash inizia con 00111.




Mostrare poi come si modifica la stessa struttura, se, invece dell'inserimento sopra discusso, si hanno due inserimenti, di record con valori della funzione di hash che iniziano rispettivamente con 11001 e 11111.



**Domanda 3** (20%)

Considerare le relazioni R1 ed R2 e l'indice I2 su R2 schematizzati sotto. I riquadri interni indicano i blocchi e il numero a fianco a ciascun riquadro indica l'indirizzo del blocco. Nell'indice, i valori numerici sono riferimenti ai blocchi (blocchi dell'indice, per la radice e il livello intermedio, e blocchi di R2 per le foglie).



Supponendo di disporre di un buffer di **otto** pagine, considerare l'esecuzione del join di R1 ed R2, sulla base dei valori del secondo attributo di R1 e del primo di R2, con un **nested loop con accesso diretto** tramite l'indice di R2.

Indicare gli indirizzi dei blocchi su cui si eseguono operazioni di pin (o fix) per produrre le prime quattro ennuple del risultato.

901, 63, 86, 98, 722, — produce la ennupla (X01, LB, ...)

63, 84, 92, — cerca AF in R2

63, 86, 98, 729, — produce la ennupla (W73, LA, ...)

63, 88, 96, 721, — produce la ennupla (Z55, GC, ...)

802, 63, 88, 95, 727 — produce la ennupla (Y01, EF, ...)

Assumendo una politica di rimpiazzo *LRU*, indicare gli indirizzi dei blocchi effettivamente letti da memoria secondaria e caricati nel buffer (nell'ordine) per produrre le prime quattro ennuple del risultato.

901, 63, 86, 98, 722,

84, 92,

729,

88 (rimpiazza 722), 96 (rimpiazza 84), 721(rimpiazza 92)

802 (rimpiazza 86), 95 (rimpiazza 98), 727 (rimpiazza 729)

In tal caso, indicare gli indirizzi dei blocchi che si può presumere si trovino nei buffer nel momento in cui si produce la quarta ennupla.

901, 63, 88, 96, 721, 802 , 95, 727

**Domanda 4** (15%)

Considerare un sistema distribuito con tre nodi  $N_1$ ,  $N_2$  e  $N_3$ , che eseguono due transazioni  $T_x$  e  $T_y$  che coinvolgono i tre nodi, in modo diverso. Per la prima transazione  $N_1$  è il coordinatore, mentre per la seconda il coordinatore è  $N_2$ . I due coordinatori inviano, come riportato nello schema sottostante, le richieste di **prepare**. Il nodo  $N_3$  va in crash subito dopo aver risposto alla prima richiesta (senza avere il tempo di ricevere il messaggio di **commit**) e prima di ricevere la seconda. Poi va in crash anche il nodo  $N_1$ . Indicare, nello schema sottostante, una possibile sequenza di scritture sui log e invio di messaggi (che includa anche i passi sopra illustrati), supponendo che entrambi i nodi siano ripristinati abbastanza presto (ma che vengano persi alcuni messaggi di risposta, ad esempio inviati a seguito di una decisione). Per i messaggi si usi la notazione *tipo(transaz)→destinatari* (come nell'esempio: **prepare**( $T_x$ )→ $N_2, N_3$ ). Supporre che nel log del coordinatore si scrivano solo i record di **prepare**, **commit** e **complete**, con i messaggi gestiti invece in memoria. Indicare ragionevoli istanti per i timeout, che permettano di concludere il protocollo per entrambe le transazioni.

Nodo $N_1$		Nodo $N_2$		Nodo $N_3$	
Log	Messaggi	Log	Messaggi	Log	Messaggi
<b>prep</b> ( $T_x, N_2, N_3$ )	<b>prep</b> ( $T_x$ )→ $N_2, N_3$	<b>ready</b> ( $T_x$ )	<b>ready</b> ( $T_x$ )→ $N_1$	<b>ready</b> ( $T_x$ )	<b>ready</b> ( $T_x$ )→ $N_1$ <i>crash</i>
<b>commit</b> ( $T_x$ )	<b>commit</b> ( $T_x$ )→ $N_2, N_3$	<b>commit</b> ( $T_x$ )	<b>ack</b> ( $T_x$ )→ $N_1$		
<b>ready</b> ( $T_y$ )	<b>ready</b> ( $T_y$ )→ $N_2$ <i>crash</i>	<b>prep</b> ( $T_y, N_1, N_3$ )	<b>prep</b> ( $T_y$ )→ $N_1, N_3$		
	<i>restart</i>	<b>abort</b> ( $T_y$ )	<b>abort</b> ( $T_y$ )→ $N_1, N_3$		
<b>abort</b> ( $T_y$ )	<b>ack</b> ( $T_y$ )→ $N_2$		<b>ack</b> ( $T_x$ )→ $N_1$		
	<b>commit</b> ( $T_x$ )→ $N_3$		<b>abort</b> ( $T_y$ )→ $N_1, N_3$		<i>restart</i>
		<b>complete</b> ( $T_y$ )	<b>abort</b> ( $T_y$ )→ $N_3$	<b>abort</b> ( $T_y$ )	<b>ack</b> ( $T_y$ )→ $N_2$
<b>complete</b> ( $T_x$ )				<b>commit</b> ( $T_x$ )	<b>ack</b> ( $T_x$ )→ $N_1$

## Basi di dati II — 19 settembre 2019

**Domanda 5** (30%) Si consideri la seguente base di dati, relativa alle ricette acquisite da un insieme di farmacie:

- Ricette(Numero, CodFarmacia, CFPaziente, Data)
- Farmacie(CodFarmacia, Nome, CodIndirizzo)
- ElementiRicetta(NumeroRicetta, CodFarmaco, Quantità)
- Farmaci(Codice, Descrizione, CodMolecola, CodCasa, Prezzo, Fascia)
- Molecole(CodMolecola, Descrizione)
- Pazienti(CF, Cognome, Nome, DataNascita, CodIndirizzo)
- CaseFarmaceutiche(CodCasa, Nome)
- ASL(Codice, Nome)
- Territorio(CodIndirizzo, Via, NumeroCivico, Comune, ASL)

Ci sono dati che cambiano nel tempo fra cui prezzi e fasce ('A', 'B' o 'C') dei farmaci e indirizzi dei pazienti.

Costruire, in tale contesto, uno schema a stella che permetta di analizzare le prescrizioni (quantità e prezzi complessivi) rispetto a

- data (dimensione standard i cui dettagli possono essere omissi);
- farmaci, con le loro proprietà (molecola e casa farmaceutica);
- prescrizione di farmaci nella stessa ricetta
- ASL di residenza e fascia d'età (ad esempio, 0-3,4-17, 18-30, ...; ma potrebbero variare) dei pazienti;
- ASL della farmacia

Supportare che, per ovvie ragioni di privacy, non possano essere riportati dati che permettano di risalire alle identità dei pazienti (CF, cognome, nome, data di nascita e indirizzo) **Indicare esplicitamente la grana dei fatti.**

Grana dei fatti: la grana scelta è "singole prescrizioni"

Schema dimensionale:

- FattiPrescrizioni(KData, KVersioneFarmaco, KRicetta, KASLfarmacia, KASLpaziente, KEtà, Quantità, Importo)
- DimFarmaci(KVersioneFarmaco, Codice, Descrizione, CodMolecola, DescrizioneMolecola, CodCasa, NomeCasa, Fascia)
- DimASL(KASL, CodiceASL, NomeASL)
- DimEtà(KEtà, Età, Fascia ...)
- DimData(KData, ...)

Commenti:

- sono indicate chiavi ad hoc per le dimensioni
- *Ricetta* è una dimensione "degenere," cioè senza attributi
- per la privacy, si eliminano tutte le informazioni personali, indicando solo ASL del paziente e fascia d'età; quindi la grana scelta è "singole prescrizioni;" in effetti, vista la presenza di *KRicetta*, tutte le dimensioni, a parte *Ricetta* e *Farmaci*, sono secondarie
- *Farmaci* è una slowly changing dimension rispetto alla fascia
- si usa *Età* invece di fascia di età, per dare un po' di flessibilità
- è opportuno avere due viste su DimASL, poiché la dimensione è utilizzata due volte

## Basi di dati II — 19 settembre 2019

Descrivere, informalmente, ma in modo strutturato e comprensibile, il processo di ETL che porta alla tabella dei fatti mostrata in risposta alla domanda precedente

- join delle relazioni RICETTE, ELEMENTIRICETTA, PAZIENTI, FARMACIE, due volte TERRITORIO (per la ASL) e FARMACI (per il prezzo)
- calcolo dell'età del paziente
- proiezione sugli attributi rilevanti:
- calcolo dell'importo (moltiplicazione del prezzo con la quantità)
- sostituzione degli identificatori o dei valori (a seconda dei casi) con le chiavi surrogate delle dimensioni