



# 資料庫系統管理

Database System Management

並行控制與回復

Concurrency Control and Recovery

資訊管理學系 陳士杰老師



國立聯合大學  
NATIONAL UNITED UNIVERSITY

# Outlines

- 並行控制 (Concurrency Control)
- 復原 (Recovery)

【講義：Ch. 7, Section 2與Section 3】

【原文：Ch. 14】

❖注意❖

在本單元中，DML指令包含DQL指令

# ■ 並行控制(Concurrency Control)

## ■ 定義：

- 讓多個交易可以在同一時間存取同一筆資料，稱之為**並行**。
- **並行控制**即讓多筆交易在並行的狀況下運作，而不會互相干擾，確保交易間的**孤立性(Isolation)**，以及提高交易的**效率**。

## ■ 目的：

- 多筆交易可同時進行，而不互相干擾
- 減低交易**回應時間**(Response Time)
- 增加交易**產出**(Throughput)

## 並行控制不佳可能產生的問題

- 遺失更新(Lost Update)
- 不一致分析(Inconsistent Analysis)
- 未確認相依(Uncommitted Dependency)

## 遺失更新


- 當有多筆交易交錯執行，且這些交易針對**相同資料項目**作存取或異動時，可能會使此資料項目的內容值**不正確**(發生不可預期的錯誤)，稱為**遺失更新**。

- 例：假設我有一個帳號 $x$ ，其中 $x = 500$

- $(父) T1: x = x+100 \Rightarrow (\text{操作} : r_1(x), x = x+100, w_1(x))$

- $(母) T2: x = x+250 \Rightarrow (\text{操作} : r_2(x), x = x+250, w_2(x))$

DB in H.D.



T1

- ①  $\langle \text{read}(x), T_1 \rangle$
- ②  $x = x + 100$   
(暫存於記憶體)
- ⑤  $\langle \text{write}(x), T_1 \rangle$

T2


- ③  $\langle \text{read}(x), T_2 \rangle$
- ④  $x = x + 250$   
(暫存於記憶體)
- ⑥  $\langle \text{write}(x), T_2 \rangle$

時間

- T1對x的更新動作(即：動作②)遺失。
  - $\because$  程式執行過程中，同一個變數會被存放在相同的記憶體空間中。
- 會產生遺失更新的排程 “**一定不是**” 可序列化排程
  - 可序列化排程一定要確保結果是正確的。

# 不一致分析

- 又稱**不正確總合(Incorrect Summary)**問題。
- 一筆交易正在針對某些資料項目作**聚合函數(Aggregate Function)**之計算，若此時其中一個資料項目被其它交易更改，造成此聚合函數計算出之結果不正確。
  - 例：假設我有兩個帳號x和y，其中x=500且y=200。現有兩個交易T1和T2：
    - T1:  $\text{SUM}(x, y) = x+y$   
⇒ (操作 :  $r_1(x)$ ,  $T = T+x$ ,  $r_1(y)$ ,  $T=T+y$ ) , T初始值為0
    - T2: 轉250元從x到y  
⇒ (操作 :  $r_2(x)$ ,  $x = x-250$ ,  $w_2(x)$ ,  $r_2(y)$ ,  $y=y+250$ ,  $w_2(y)$ )




- Total之加總動作擷取了不一致的資料(因時間點不一致所造成!!)。

# 未確認相依

- 又稱**Dirty Reads**或**Temporary Update**。
- 交易A已更新某一個資料項目，但尚未確認(Commit)時，此資料項目卻又被另一個交易B所存取，但是先前的交易A因故需要**撤回(Abort/Rollback)**，則交易B讀到了一個不應該讀的項目值。
  - 例：假設有兩個帳號x和y，其中 $x=100$ 且 $y=200$ 。現有兩個交易T1和T2：
    - (母) T1:  $x = x+100$ ，但轉帳中途撤回  
 $\Rightarrow$  (操作： $r_1(x)$ ,  $x = x+100$ ,  $w_1(x)$ , Abort)
    - T2: 轉200元從x到y  
 $\Rightarrow$  (操作： $r_2(x)$ ,  $r_2(y)$ ,  $x = x-200$ ,  $y=y+200$ ,  $w_2(x)$ ,  $w_2(y)$ )

[

]



- T<sub>2</sub>讀取到錯誤的x值(尚未確認的x值，即Dirty data)。

# 交易並行時可能會發生的問題


- 死結(Deadlock)
- 活結(Livelock)
- 餓死(Starvation)

# 死結(Deadlock)

- 當兩個以上的交易同時進行，彼此皆佔有某些資源，但亦企圖奪取對方資源時（即：陷入“**互相等待對方所擁有之資源**”），便會發生死結的現象。

## Example

- 假設系統中有兩個資源  $R_1$  與  $R_2$ ，而且該系統產生兩個交易  $T_1$  與  $T_2$



- $R_1$  已配置給  $T_2$ ， $R_2$  已配置給  $T_1$ ，但這兩個交易在執行過程中又向對方要求對方正在使用中的資源，因此造成系統打結。

## ■形成死結的四個條件 (缺一不可) :

- **Mutual exclusion (互斥)**

- 同一資源不可同時被兩個以上的交易共用，即資源被鎖定後，其它交易不可存取此資源。

- **Hold and wait (持有並等待)**

- 各交易皆佔有某些資源，並等候其它交易釋放其資源。

- **No preemption (不可搶奪)**

- 不可搶奪已被佔用的資源。

- **Circular waiting (循環式等候)**

- 各交易循環等待對方資源，即：優先順序圖(Precedence Graph)形成迴圈

# 活結(Livelock)與餓死(Starvation)

- 某交易在一段不確定的時間內無法進行，然而其它交易卻可以正常進行的情況，稱之為**活結**。
  - 舉例：
    - 若交易有**優先權**之概念，且優先權高的交易持續得到資源的授與，則優先權低的交易即可能進入活結的狀態 (一直拿不到資源)
- **餓死(Starvation)**
  - 為活結的衍生問題，特定交易可能永遠無法獲得所需資源的情況。
  - 優先權高的交易優先被執行，並不斷有新的高優先權交易進入，造成優先權最低的交易被選為Victim(犧牲者)，永遠無法執行。

## ■ 等-死方法 (wait-die):

- 當交易  $T_i$  要求一個正被  $T_j$  持有的資源時，只要  $T_i$  的時間戳記比  $T_j$  小 (即： $T_i$  比  $T_j$  早進入資料庫系統)， $T_i$  就被允許等待。否則的話， $T_i$  就被撤回。
  - 較早進入的交易可等待，較晚進入的交易被撤回。
  - 撤回動作較多。
- 例如，假設  $T_1$ 、 $T_2$  與  $T_3$  的時間戳記分別為 5、10 和 15。如果  $T_1$  要求一個  $T_2$  所持有的資源， $T_1$  將會等待。如果  $T_3$  要求一個  $T_1$  交易所持有的資源， $T_3$  將被撤回。
- 以不可搶奪(No preemption)為基礎

## ■ 傷-等方法 (wound-wait scheme):

- 是等-死方法的相反。當交易  $T_i$  要求一個正被  $T_j$  持有的資源，如果  $T_i$  的時間戳記比  $T_j$  大 (即： $T_i$  比  $T_j$  晚進入資料庫系統)，那麼  $T_i$  就被允許等待。否則， $T_i$  就把  $T_j$  的資源給搶奪過來， $T_j$  就被撤回。
    - 較早進入的交易可搶較晚進入交易之資源，而較晚進入的交易則需等待。
    - 撤回動作較少。
  - 以可搶奪 (Preemption) 為基礎
- 上述兩種方法皆可避免飢餓情況，因為若撤回的交易繼續使用原本的時間戳記並重新要求資源，則其時間戳記終究會成為系統中最小的一個。

# ■ 並行控制的技術

## ■ 鎖定(Locking)

- 當某交易欲存取特定資料項目時，必須將此資料**鎖住(Lock)**，直到存取完畢才解除**鎖定(Unlock)**。
- 若其它交易欲存取被鎖定的資料項目時，需等待至其解除鎖定。

## ■ 時間戳記(Timestamp)

- 每個交易依其進入資料庫系統的時間先後，給予一個**時間戳記**，以時間戳記的大小來判交易之**優先權(Priority)**。
- 若有交易欲存取某資料項目時，必須更新**存取此資料項目的時間戳記**。

## ■ 多重版本並行控制(Multi-version Concurrency Control)

- 以時間為基礎，會在每次資料項目被修改時，**保留舊的版本**。所以在並行執行時，會自動選擇合適的版本資料以避免不一致的情況。
- 較浪費空間。

## ■ 樂觀並行控制(Optimistic Concurrency Control)

- 假設所有交易皆可順利且正確地進行，所以**不須在交易期間作任何的檢查**，直到交易完成才從事檢查。
- 若交易違反可序列化(Serializable)的結果，則選擇**影響較小**之交易作撤回(Abort)。


## 鎖定(Locking)

- 鎖定是利用一個與資料庫中資料項目相結合的變數，以描述資料項目的狀況，並決定何種動作允許或不允許應用在此資料項目上。
- 並行控制的鎖定技術主要有：
  - 二元鎖定 (Binary Locking)
  - 共享互斥鎖定 (Shared and Exclusive Locking)
  - 兩階段鎖定 (Two Phase Locking)

# 二元鎖定 (Binary Locking)

## ■ 概念：

- 交易欲存取資料項目x時，即將x鎖定，直到存取完畢，再解除對x的鎖定。
- 所以，二元鎖定技術對於被交易使用到的資料項目 x 分成兩種狀態：
  - **鎖定(Lock)**：若資料項目x被鎖定，表示此資料項目x不能被其它交易存取。
  - **解除鎖定(Unlock)**：若資料項目x解除鎖定，表示此資料項目x可以被其它交易存取。



: 對資料庫的R/W操作

## ■ 二元鎖定的缺點：

- 不能保證排程為可序列化 (Serializable) (∴所以不保證排程中所有交易執行後的結果一定是正確的。)
- 可能產生死結 (Deadlock)
- 可能產生活結 (Live Lock) 或 餓死 (Starvation) 狀態
- 並行程度不佳

# 共享互斥鎖定 (Shared and Exclusive Locking)

- 由於二元鎖定過於嚴格，且並行程度不佳：
  - 事實上，若有多筆交易同時欲存取資料項目x，但皆只是從事**讀取(Read)**的動作時，沒有必要將此資料項目完全鎖定；只有在從事**寫入(Write)**動作時，才需要將此資料項目x獨佔式地鎖定。
- 共享互斥鎖定又稱**多元鎖定(Multi-Mode Locking)**，將二元鎖定中的Lock分為**共享鎖定 (Share Lock)**與**互斥鎖定 (Exclusive Lock)**兩種，較二元鎖定有彈性。

T1	T2	Read Lock	Write Lock
Read Lock		共享	互斥
Write Lock		互斥	互斥

- **共享互斥鎖定技術對於被交易使用到的資料項目  $x$  分成三種狀態：**

- **共享鎖定(Shared-Lock)**：又稱讀取鎖定(Read-Lock)。若資料項目 $x$ 被共享鎖定，表示此資料項目 $x$ 仍可被其它交易所讀取。
- **互斥鎖定(Exclusive-Lock)**：又稱寫入鎖定(Write-Lock)。若資料項目 $x$ 被互斥鎖定，表示此資料項目 $x$ 不能被其它交易讀取或寫入，只有該交易本身可獨佔使用此資料項目。
- **解除鎖定(Unlock)**：若資料項目 $x$ 解除鎖定，表示此資料項目 $x$ 可以被其它交易所存取。



## ■ 鎖定的升級與降級：

- 升級(Upgrade)：Unlock→Read Lock→Write Lock
  - 即由Unlock→Read Lock， Unlock→Write Lock或Read Lock→Write Lock的狀態。
- 降級(Downgrade)：Write Lock → Read Lock→Unlock
  - 即由Read Lock→Unlock， Write Lock →Unlock或Write Lock → Read Lock的狀態。

## ■ 共享互斥鎖定的缺點：

- 不能保証排程為可序列化 (Serializable) (∴所以不保証排程中所有交易執行後的結果一定是正確的。)
- 可能產生死結 (Deadlock)
- 可能產生活結(Live Lock)或餓死 (Starvation)狀態

# 共享互斥鎖定範例

- 假設有兩個交易T1與T2，若分開執行可得到正確之結果：


<u>T1</u>	<u>T2</u>	<u>結果</u>
read_lock (Y); <b>read_item (Y);</b> unlock (Y); write_lock (X); <b>read_item (X);</b> <b>X:=X+Y;</b> <b>write_item (X);</b> unlock (X);	read_lock (X); <b>read_item (X);</b> unlock (X); Write_lock (Y); <b>read_item (Y);</b> <b>Y:=X+Y;</b> <b>write_item (Y);</b> unlock (Y);	初值：X=20; Y=30  循序排程 <b>先T1再T2</b> 的結果： X=50, Y=80  循序排程 <b>先T2再T1</b> 的結果： X=70, Y=50

$T_1$	$T_2$	
<pre>read_lock(Y); read_item(Y); unlock(Y);</pre>	<pre>read_lock(X); read_item(X); unlock(X); write_lock(Y); read_item(Y); Y:=X+Y; write_item(Y); unlock(Y);</pre>	
<pre>write_lock(X); read_item(X); X:=X+Y; write_item(X); unlock(X);</pre>		排程 S 的結果： $X=50, Y=50$ (不是可循序的)

- (a) 兩個交易  $T_1$  和  $T_2$ ；(b)  $T_1$  和  $T_2$  的循序排程結果；  
 (c) 使用鎖定機制的非循序排程  $S$

# 兩階段鎖定 (Two Phase Locking; 2PL)

- 2PL限定每一個交易中**所有的鎖定動作(含升級)，必須在所有解除鎖定(含降級)動作之前**。
- 因此，2PL分成兩個階段：
  - **擴展階段(Expanding)**：
    - 又稱成長階段(Growing)，擴展階段允許加入新的鎖定或升級動作，但不允許解除任何鎖定。
  - **收縮階段(Shrinking)**：
    - 又稱釋放階段(Releasing)，收縮階段允許解除現存鎖定或降級動作，但不允許任何新的鎖定加入。



註：此排程服從 2PL，所有鎖定動作皆在所有解除鎖定之前。

## ■ 2PL的種類：

- **基本型 (basic) 2PL**：交易會逐漸鎖定資料項目
  - 可能會有死結
- **保守型 (conservative)2PL**：在交易執行前，先鎖定所有需要的資料項目。若有任何資料項目無法鎖定，則全部不鎖，直到可完全鎖定所有資料項目再開始交易。
  - 不太會有死結
  - 擴展階段短，收縮階段長
- **嚴格型 (strict)2PL**：交易過程中，不會解除任何鎖定，直到交易結束(Commit或Rollback)時，再一次釋放所有鎖定。
  - 可能會有死結
  - 擴展階段長，收縮階段短

- 2PL的優點：
  - 遵守2PL要求而執行完畢的排程，保証皆為**可序列化排程**
- 2PL的缺點：
  - 可能產生死結 (Deadlock)
  - 可能產生活結(Live Lock)或餓死 (Starvation)狀態
  - 2PL可能保持某個鎖定過久，造成其它交易無法順利進行

# 時間戳記排序法(Timestamp Ordering)

- 時間戳記是根據交易被送到資料庫系統的時間所指定出來的，所以可將時間戳記當作是交易開始時間。
  - 在此，將交易T的時間戳記表示為TS(T)。
  - 以時間戳記為基礎的並行控制技術不需要鎖定資料項目，所以不會造成死結。
- 定義：
  - 由資料庫系統指定給每一個交易一個獨特的唯一識別碼(Identifier)，以辨認各個交易的順序。
  - 通常時間戳記值會依照交易進入系統的順序排列，所以可以想像成交易開始的記號。
  - 時間戳記一般利用計數器 (Counter)產生流水號給各個交易，或是讀取系統時鐘 (Clock)值給各個交易。

## ■ 時間戳記並行控制技術，針對每一個資料項目會使用到兩種不同的時間戳記：

### ○ **Read-TS(x)**：

- 資料項目x的讀取時間戳記，表示所有已成功讀取資料項目x的交易中，時間戳記最大的。
- 例如： $\text{Read-TS}(x) = \text{TS}(T_i)$ ，則代表交易 $T_i$ 是所有成功讀取資料項目x的交易中，最年輕的交易。

### ○ **Write-TS(x)**：

- 資料項目x的寫入時間戳記，表示所有已成功寫入資料項目x的交易中，時間戳記最大的。
- 例如： $\text{Write-TS}(x) = \text{TS}(T_i)$ ，則代表交易 $T_i$ 是所有成功寫入資料項目x的交易中，最年輕的交易。

# 基本時間戳記排序法

- 一個交易T不論是執行read或是write時，均會產生一個時間戳記 $TS(T)$ 。
- 交易T執行一個**write x**動作：
  - 若Read-TS(x) > TS(T) 或 Write-TS(x) > TS(T)，則**write操作不允許**，並將**交易T取消並撤回 (Abort/Rollback)**。
    - 理由：這是因為有一些比交易T晚進入系統的其它交易，在交易T進行寫入資料項目 x 的操作時，已對 x 做過讀取或寫入!!若允許交易T的寫入，將造成**資料不一致**的現象。
  - 若無上述狀況，則**執行交易T的write操作**，並設定**write-TS(x) = TS(T)**

## ■ 交易T執行一個read x動作：

- 若 Write-TS(x) > TS(T)，則**read操作不允許**，並將**交易T取消並撤回 (Abort/Rollback)**。
  - 理由：這是因為有一些比此交易T晚進入系統的其它交易，在交易T進行讀取資料項目 x 的操作時，已對 x 做過寫入!!
- 若  $\text{Write-TS}(x) \leq \text{TS}(T)$ ，則**執行交易T的read操作**，並設定**read-TS(x) = \text{Max}[\text{TS}(T), \text{原本 read-TS}(x)]**

# 以時間戳記排序法避免遺失更新問題

例：假設我有一個帳號x，其中 $x = 500$


(父) T1:  $x = x+100 \Rightarrow$  (操作 :  $r_1(x)$ ,  $x = x+100$ ,  $w_1(x)$ )，且  $TS(T1) = 3$

(母) T2:  $x = x+250 \Rightarrow$  (操作 :  $r_2(x)$ ,  $x = x+250$ ,  $w_2(x)$ )，且  $TS(T2) = 8$

針對帳號 x，用到兩個時間戳記  $read-TS(x)$  與  $write-TS(x)$ ：

操作時間點	初始						
read-TS(x)							
write-TS(x)							

交易T1在  
時間點⑤被撤回



## ■ 時間戳記並行控制優點：

- 保証排程皆為**可序列化(Serializable)**
- 避免死結(Dead lock)發生
- 結合wait-die或wound-wait方法可避免活結 (Live lock) 或餓死 (Starvation)發生。

## ■ 時間戳記並行控制缺點：

- 可能產生**連鎖性撤回 (Cascading Rollback)**，降低執行效率。

# 樂觀並行控制(Optimistic Concurrency Control)

- 先前討論過的並行控制技術中，於資料庫動作執行之前都必須完成一定程度的檢查，例如：
  - **鎖定機制**需要先檢查資料項目 x 目前的鎖定狀態。
  - **時間戳記作法**必須檢查交易的時間戳記。
- 但是，過多的檢查步驟會使得**交易的執行效率降低**。
- 樂觀並行控制技術的觀念：
  - 假設所有交易皆可順利且正確地進行，因此在交易執行過程中**不需要作任何的檢查動作**。
  - 交易執行時，任何對資料項目的變更操作 (即：Write操作) 並非直接對資料庫進行修改，而是**對該資料項目的複製版本(Copy)進行修改，等到交易結束時再去檢查這些變更操作是否符合可序列化特性**。
  - 確認符合可序列化特性時，再從副本**變更到資料庫中**；反之，則交易將被撤回(Abort)

## ■ 樂觀並行控制技術有3個階段：

- 讀取 (Read)：交易可以從資料庫中讀取資料項目，並同時產生此資料項目的複本。而變更資料項目的操作只會修改到此資料項目的複本。
  - 確認 (Validation)：執行檢查，以確保交易修改到資料庫的操作沒有違反可序列化。
  - 寫入 (Write)：如果認階段成功，交易的更新資料會被寫入資料庫；否則將取消變更操作，且交易被撤回。
- ## ■ 樂觀並行控制技術適用於交易甚少發生不一致的情況，可提升交易的執行效率。
- 樂觀並行控制在確認階段一次做完所有的檢查，可以讓花在檢查上的時間最少。如果交易之間幾乎沒有不一致情況，那麼大部份的交易將會被成功確認。
  - 然而，若有太多的交易造成不一致的衝突，會造成許多執行完的交易必須放棄它們的結果而被撤回。

## ■ 樂觀並行控制的優點：

- 保証排程皆為可序列化
- 避免死結發生
- 結合Wait-die或Wound-wait方法可避免活結或餓死發生
- 不一致情況甚少發生時，可加快系統執行效率

## ■ 缺點：

- 若經常發生不一致的狀況，樂觀並行控制會產生大量的撤回或復原工作。

# 多重版本並行控制(Multi-version Concurrency Control)

- 以時間為基礎，當每回資料項目被修改時**保留舊的版本**，所以在多個交易並行執行時，會自動選擇合適的版本以避免不一致的情況。
- 優點：
  - 保証排程皆為可序列化
  - 避免死結發生
  - 結合Wait-die或Wound-wait方法可避免活結或餓死發生
  - 加快讀取及寫入速度
- 缺點：
  - 可能產生**連鎖性撤回(Cascading Rollback)**，降低執行效率
  - 需要較多**記憶體**，以維持每個資料項目的多個版本

# ■ 並行控制技術的比較

	Serializable	Dead Lock	Live Lock	Starvation
二元鎖定	不一定	可能發生	可能發生	可能發生
共享互斥鎖定	不一定	可能發生	可能發生	可能發生
兩階段鎖定	是	可能發生	可能發生	可能發生
時間戳記	是	可避免	結合Wait-die、Wound-wait則可避免	結合Wait-die、Wound-wait則可避免
多重版本	是	可避免	結合Wait-die、Wound-wait則可避免	結合Wait-die、Wound-wait則可避免
樂觀並行控制	是	可避免	結合Wait-die、Wound-wait則可避免	結合Wait-die、Wound-wait則可避免


# ■ 復原 (Recovery)

## ■ 定義：

- 復原是指在資料庫系統發生失敗(failure)後，重新回到一個已知的正確狀態的方法。

## ■ 失敗的種類：

- 非毀滅性故障
- 毀滅性故障



## ■ 非毀滅性故障：

- 一般是指導致主記憶體資料內容消失，但永久性儲存媒體中的資料仍完好的狀態。可能的情況如下：
  - 交易或系統錯誤 (transaction or system error)：在交易執行時的部份操作可能導致故障，例如：溢位、除以零或是使用者強行中斷交易。
  - 交易偵測到例外狀況(exception condition)：程式偵測到一些例外狀況，可能導致交易無法繼續執行，例如：找不到所需的值。
  - 強制實行並行控制(concurrency control enforcement)：交易違反序列性 (Serializability)或發生死結(Deadlock)時，系統可能會主動要求交易撤回 (Abort/Rollback)。
  - 電腦失敗(Computer failure)：電腦系統本身發生的硬體或軟體錯誤，造成程式中斷或當機等狀況，以致於記憶體內資料消失。
- 復原方式：
  - 利用系統日誌(System Journal, System Log)從事復原。

## ■ 毀滅性故障：

- 一般指硬體上的故障，又稱為媒體故障(Media failure)、硬體當機(Hard crash)。可能情況如下：
  - 磁碟失敗(Disk failure)：交易中遇到磁碟軌損壞、讀寫頭損毀、磁碟錯誤讀寫等錯誤，造成硬體資料的損失。
  - 實體問題與大災難(Physical Problems and Catastrophes)：交易中可能遭遇硬體被蓄意破壞、火災、水災...等嚴重故障導致失敗。
- 復原方式：
  - 利用磁帶、磁碟、光碟等**定期備份的資料**從事復原動作。

# 復原的基本方法

- 針對非毀滅性故障：
  - 系統運作時，將所有改變資料項目的操作寫入系統日誌(System Journal)中，並將此系統日誌儲存於永久性儲存媒體。
  - 由於非毀滅性故障並未真正損毀實體磁碟上的系統日誌或資料庫，因此只要針對系統日誌中的紀錄進行復原的動作即可。
- 針對毀滅性故障：
  - 系統日常運作時，即定期將資料庫的內備份(Backup、Dump)至其它儲存媒體，並將此備份資料與日常資料庫放置於不同地點。
  - 發生毀滅性故障時，將備份資料回存至資料庫中，並將此期間的系統日誌進行重做(Redo)，以獲得正確完整的資料庫內容。

# ■ 交易回復技術

## ■ 延遲更新 (Deferred Update)

- 採用No-Undo/Redo演算法

## ■ 立即更新 (Immediate Update)

- 採用Undo/Redo演算法
- 採用Undo/No-Redo演算法

## ■ 投影 (Shadowing/Shadow Paging)

- 採用No-Undo/No-Redo演算法

## ■ Undo/Redo回顧：

- **Undo**：交易尚未Commit時，因某些因素將部份的資料變更寫入到H.D.中的資料庫，此時若系統失敗欲復原時，須將此部份的資料變更徹消並回復。
- **Redo**：交易已Commit但尚未將資料變更寫入到H.D.中的資料庫時，若系統失敗欲復原，則須將此部份的資料變更動作重作，以確保變更可進入到資料庫中。

# 延遲更新 (Deferred Update)

- 觀念：延遲任何真正寫入資料庫的更新，直到交易成功的完成並且到達確認點(Commit Point)為止。
  - 當一個交易尚未執行到確認點(Commit Point)之前，其所有對資料庫資料項目之更改操作，皆紀錄在主記憶體的工作區塊(Block)或是系統日誌(System Journal)中，而不會真正修改到資料庫的內容。
  - 當交易到達確認點時，交易操作紀錄會強制寫入到磁碟上的系統日誌，並保証此交易將會真正改變資料庫的內容。

# 延遲更新下，不同時間點之交易處理

## ■ 交易未Commit前：



## ■ 已Commit，但尚未到達Checkpoint：



## ■ 已Commit，且已到達Checkpoint：



## 復原工作

No-Undo  
(無須處理)

### 交易未Commit前：



### 已Commit，但尚未到達Checkpoint：



Redo

### 已Commit，且已到達Checkpoint：




無須處理


- 由於尚未到達確認點的交易，所有的更新操作都不會影響到資料庫的內容。因此若交易在確認點之前發生錯誤，則此交易**不需做Undo**的工作，可忽略此交易之復原動作。
- 到達確認點的交易若發生錯誤，需**進行Redo**的工作，以確認此交易真正改變資料庫的內容。
  - Redo工作必須是等冪(Idempotent)的，即：無論交易操作被執行幾次，其結果皆等同於只執行一次。
- 由於延遲更新在當系統發生非毀滅性故障時，不需進行Undo工作，只需進行Redo工作，因此這種技術又被稱為**No-Undo/Redo**演算法。

# 實作延遲更新的復原程序

- 建立作用中(Active)與未確認(Uncommitted)的Undo串列，  
以及建立最後一個檢查點之後已確認(Committed)的Redo串列。
  - 某交易開始時，將此交易記載於Undo串列；
  - 某交易Commit時，將此交易自Undo串列移到Redo串列；
  - 到達Check Point時，清空Redo串列。
- 系統發生錯誤後，Undo串列中的交易操作將被忽略取消，  
不需從事Undo工作。
- 系統發生錯誤後，從Redo串列取出已確認的交易操作，並  
重新執行 (Redo)此串列中的寫入(Write)動作。

## ■ 範例：針對五個交易之延遲更新：





Ans:

○ 建立Undo/Redo串列：

○ 系統失敗前 (時間 9)

■ Undo串列： $\{T_3, T_5\}$

■ Redo串列： $\{T_2, T_4\}$

○ 因此，系統失敗後：

■ Redo串列中的 $T_2, T_4$ 交易之寫入操作，將被**重新執行(Redo)**

■ Undo串列中的 $T_3, T_5$ 交易操作被忽略，**不需執行任何動作(No-Undo)**

■ 在檢查點之前就已Committed的 $T_1$ 交易，不需執行任何動作

時間	Undo串列	Redo串列
1	$T_1$	
2	$T_1, T_2$	
3	$T_1, T_2, T_3$	
4	$T_2, T_3$	$T_1$
5	$T_2, T_3$	(清空)
6	$T_2, T_3, T_4$	
7	$T_2, T_3, T_4, T_5$	
8	$T_3, T_4, T_5$	$T_2$
9	$T_3, T_5$	$T_2, T_4$

# 延遲更新的缺點

- 當系統日誌內的資料量龐大時，十分浪費時間。
  - $\because$  Redo動作費時。
- 經常進行一些不必要的動作，例如大部份的更新可能已被寫入資料庫中，卻**重複執行Redo**動作。
  - 已Committed但尚未到達Checkpoint的資料，有可能已寫入資料庫中。
  - 可結合**Checkpoint**以減少或解決此一問題。
    - $\because$ 一旦發生Check point，表示此point之前已Committed的資料已確實寫入資料庫中，所以不用Redo。

## 立即更新(Immediate Update)

- 以立即更新為基礎的回復技術，主要是當交易發出一個資料更新(Write)命令時，位於硬碟上的**系統日誌**或**資料庫**可以立即被強制更新，不需要等待交易到達其確認點。
- 因此，交易若在未到達確認點前失敗，需進行**Undo**的動作，以復原到先前的狀態。
- 立即更新的回復技術分成兩種類型，視**立即更新到何種程度**來決定：
  - **Undo/Redo演算法**：交易的所有資料項目改變的操作，在確認點之前會強制寫入到**永久儲存媒體(系統日誌)**中。
  - **Undo/No-Redo演算法**：交易的所有資料項目改變的操作，在確認點之前會強制寫入到**資料庫**中。

# 立即更新下，不同時間點之交易處理(Undo/Redo)

## ■ 交易未Commit前：



## ■ 已Commit，但尚未到達Checkpoint：



## ■ 已Commit，且已到達Checkpoint：



## 復原工作

Undo

### 交易未Commit前：



### 已Commit，但尚未到達Checkpoint：



Redo

### 已Commit，且已到達Checkpoint：



無須處理

- 由於尚未到達確認點的交易之更新操作，**有可能會影響到資料庫的內容**。因此若交易在確認點之前發生錯誤，則此交易需要做**Undo**的工作。
- 到達確認點的交易若發生錯誤，需進行**Redo**的工作，以**確認此交易真正改變資料庫的內容**。
  - Redo工作必須是等冪(Idempotent)的，即：無論交易操作被執行幾次，其結果皆等同於只執行一次。
- 由於此類立即更新在當系統發生非毀滅性故障時，需進行**Undo**與**Redo**工作，因此這種技術又被稱為**Undo/Redo演算法**。

# 立即更新下，不同時間點之交易處理 (Undo/No-Redo)

## ■ 交易未Commit前：



## ■ 已Commit，但尚未到達Checkpoint：



## ■ 已Commit，且已到達Checkpoint：



## 復原工作

Undo

### 交易未Commit前：



### 已Commit，但尚未到達Checkpoint：



No-Redo  
(無須處理)

### 已Commit，且已到達Checkpoint：




無須處理


- 由於尚未到達確認點的交易之更新操作，會影響到**資料庫的內容**。因此若交易在確認點之前發生錯誤，則此交易需要做Undo的工作。
- 到達確認點的交易若發生錯誤，不需進行Redo的工作。  
( $\because$ 此交易的更新操作已經改變資料庫的內容。)
- 由於此類立即更新在當系統發生非毀滅性故障時，需進行Undo工作，但是不需要進行Redo工作，因此這種技術又被稱為**Undo/No-Redo演算法**。

# 立即更新的復原程序

- 建立作用中與未確認的Undo串列，以及建立最後一個檢查點之後已確認的Redo串列。
  - 某交易開始時，將此交易記載於Undo串列；
  - 某交易Commit時，將此交易自Undo串列移到Redo串列；
  - 到達Check Point時，清空Redo串列。
- 系統發生錯誤後，Undo串列中的交易操作將被反向進行以從事Undo工作。
- 系統發生錯誤後，
  - 從Redo串列取出已確認的交易操作，並重新執行(Redo)此串列中的寫入(Write)動作。(Undo/Redo演算法)
  - Redo串列中的交易操作將被忽略取消，不需從事Redo工作。(Undo/No-Redo演算法)

## ■ 範例：針對五個交易之立即更新(Undo/Redo演算法)：





## Ans:

### ○ 建立Undo/Redo串列：

### ○ 系統失敗前 (時間 9)

■ Undo串列： $\{T_3, T_5\}$

■ Redo串列： $\{T_2, T_4\}$

### ○ 因此，系統失敗後：

■ Redo串列中的 $T_2, T_4$ 交易之寫入操作，將被重新執行(Redo)

■ Undo串列中的 $T_3, T_5$ 交易之寫入操作，將被執行Undo工作(Undo)

■ 在檢查點之前就已Committed的 $T_1$ 交易，不需執行任何動作

時間	Undo串列	Redo串列
1	$T_1$	
2	$T_1, T_2$	
3	$T_1, T_2, T_3$	
4	$T_2, T_3$	$T_1$
5	$T_2, T_3$	(清空)
6	$T_2, T_3, T_4$	
7	$T_2, T_3, T_4, T_5$	
8	$T_3, T_4, T_5$	$T_2$
9	$T_3, T_5$	$T_2, T_4$

## 立即更新的缺點

- 每項操作皆必須**寫入永久性磁碟**，十分浪費時間。
  - $\because$  H.D.是機械式運作。
- 經常進行一些不必要的動作。
  - 例如：大部份的更新可能已被寫入資料庫中，卻仍要對所有已 Committed的交易重複執行Redo動作。(for Undo/Redo演算法)
- 尚未確認的交易亦必須進行Undo工作，浪費時間。

## ※練習範例※

有一系統日誌記錄記載五個交易如下，請分別以延遲更新與立即更新技術從事復原，並討論所需動作為何？(由左到右、由上到下)

- |   |  |   |  |
|---|--|---|--|
| ① | <u>&lt;starts, T1&gt;</u><br><u>&lt;read(x), T1&gt;</u><br><u>&lt;write(x), T1, 11, 5&gt;</u>                              | ⑦ | <u>&lt;starts, T5&gt;</u><br><u>&lt;commit, T1&gt;</u><br><u>&lt;write(x), T4, 5, 20&gt;</u> |
| ② | <u>&lt;starts, T2&gt;</u><br><u>&lt;read(y), T2&gt;</u><br><u>&lt;write(y), T2, 1, 10&gt;</u>                              | ⑧ | <u>&lt;read(y), T5&gt;</u><br><u>&lt;write(y), T5, 10, 8&gt;</u>                             |
| ③ | <u>&lt;commit, T2&gt;</u>  | ⑨ | <u>&lt;commit, T4&gt;</u>  |
| ④ | <u>&lt;starts, T3&gt;</u>  |   | <u>&lt;read(v), T3&gt;</u>   |
| ⑤ | <u>&lt;checkpoint&gt;</u>  |   | <u>&lt;write(v), T3, 1, 11&gt;</u>   |
| ⑥ | <u>&lt;starts, T4&gt;</u><br><u>&lt;read(w), T3&gt;</u><br><u>&lt;read(z), T1&gt;</u><br><u>&lt;write(w), T3, 7, 3&gt;</u> |   | <u>&lt;system crash&gt;</u>  |
|   | <u>&lt;read(x), T4&gt;</u>   |   |  |

## ■ Ans:

- 建立Undo/Redo串列：
- 系統失敗前
  - Undo串列： $\{T_3, T_5\}$
  - Redo串列： $\{T_1, T_4\}$
- 先做Undo，再做Redo
  - Redo：由前往後做
  - Undo：由後往前做

時間	Undo串列	Redo串列
1	$T_1$	
2	$T_1, T_2$	
3	$T_1$	$T_2$
4	$T_1, T_3$	$T_2$
5	$T_1, T_3$	(清空)
6	$T_1, T_3, T_4$	
7	$T_1, T_3, T_4, T_5$	
8	$T_3, T_4, T_5$	$T_1$
9	$T_3, T_5$	$T_1, T_4$

○ 採用**延遲更新**技術：

- **Undo串列**中的所有交易皆忽略。
- **Redo串列**中的T1與T4交易之寫入操作重新執行並寫入至資料庫。即執行： $\langle \text{write}(x), \text{T1}, 11, 5 \rangle$ 與 $\langle \text{write}(x), \text{T4}, 5, 20 \rangle$

○ 採用**立即更新**技術 (**Undo/Redo**演算法)：


- **Undo串列**中的T3與T5交易之寫入操作執行Undo動作。即執行： $\langle \text{write}(v), \text{T3}, 11, 1 \rangle$ 、 $\langle \text{write}(y), \text{T5}, 8, 10 \rangle$ 與 $\langle \text{write}(w), \text{T3}, 3, 7 \rangle$
- **Redo串列**中的T1與T4交易之寫入操作重新執行並寫入至資料庫。即執行： $\langle \text{write}(x), \text{T1}, 11, 5 \rangle$ 與 $\langle \text{write}(x), \text{T4}, 5, 20 \rangle$

# 投影 (Shadowing/投影分頁Shadow Paging)

- Shadowing是將資料庫視為由一些固定大小的磁碟分頁 (或磁碟區塊) 所組成。其中，有n個磁碟分頁存有資料。
- 需另外建構出具有n個項目的分頁表(Page Table，又稱目錄(Directory))，其中第i個項目是指向磁碟的第i個存有資料的磁碟分頁。
  - 當交易開始執行時，會先產生兩個不同類型的Page Table：
    - **Shadow Page Table (投影分頁表)**：用以指向交易前的原始磁碟分頁之資料，此分頁表不會被修改。
    - **Current Page Table (目前分頁表)**：用以指向交易執行期間的目前磁碟分頁之資料。
  - 當交易進行時，若欲改變資料庫中的某一磁碟分頁之資料時，會將改變的值另外存放至新的磁碟分頁，而不覆蓋舊磁碟分頁的資料。

## ■ 交易開始時：

- 一開始時Current Page Table和Shadow Page Table是一樣的。



# 交易的Commit與Recovery工作

- 交易**Committed**時：
  - 系統會**拋棄** a. 被更新過的舊磁碟分頁，以及 b. 指向舊磁碟分頁所在的Shadow Page Table。
- 交易**失敗**，需要復原時：
  - 復原時，系統將**拋棄** a. 新的磁碟分頁，以及 b. Current Page Table，採用Shadow Page Table。
- 由上可知，由於延遲更新在當系統發生非毀滅性故障時，不需進行Undo與Redo工作，因此這種技術又被稱為**No-Undo/No-Redo演算法**。

## ■ Shadowing/Shadow Paging特性：

- 在單一使用者的環境下，不需要使用到系統日誌 (System Log)即可從事復原，用2個不同類型的Page Table即可。
- 多使用者環境下，則需要用到系統日誌作並行控制。

## ■ Shadowing/Shadow Paging優點：

- Undo動作非常容易，留住Shadow Page Table即可。
- 不必進行Redo動作，留住Current Page Table即可。
- 在單一使用者的環境下，不需要使用到系統日誌即可從事復原。

## ■ Shadowing/Shadow Paging缺點：

- 若分頁表(Page Table)太大，在Commit後會耗費較多的時間寫入分頁表。
  - ∵ Shadow Page Table位於H.D.，而Current Page Table位於M.M.。當Commit時，須將位於M.M.上的Current Page Table的資料寫到位於H.D.中的Shadow Page Table。
- 磁碟分頁邏輯上 (Logically) 連續，但時常更新磁碟分頁時，會造成磁碟分頁實際上 (Physically) 分散於磁碟各處，降低存取效率。
  - ∵需定期作**磁碟重組**。

# 補 充

# ■ 兩階段確認協定(Two-Phase Commit Protocol)

## ■ 定義：

- 使用於**分散式資料庫系統環境**，讓分散於各處的資料庫可以同步執行交易的Commit與Rollback。
- 交易隨時可以與其它各自獨立的的**資源管理者(Resource Manager)**溝通，而每個資源管理者皆各自管理自己可復原的資源，並擁有及維護自己的系統日誌(System Log)。
- 此外，整個系統還有一個**總體協調者 (Coordinator)**，用以管理整個系統及各個管理者 (交易的參與者)。

## ■ 執行步驟：

- 分成**準備階段**與**行動階段**，共有5個步驟。


## 準備階段

- ① 協調者送出 “**準備確認** (Prepare to commit)” 的訊息給所有參與者 (Participant/Cohost)。
- ② 交易程序的所有參與者收到準備確認的訊息後，將自己所擁有的局部資源 (Local Resources) 強制寫入位於**永久性儲存媒體上的系統日誌**。
- ③ 參與者若成功寫入系統日誌，則發出一個 “**OK**” 的訊息給協調者；反之若寫入失敗，則發出一個 “**Not OK**” 給協調者。

## 行動階段

- ④ 當協調者收到所有參與者的 “OK” 訊息，即送出一個 “Commit” 訊息給所有參與者；反之，若收到任何一個參與者回覆的是 “Not OK”，則送出 “Rollback” 紿所有參與者。而自己也會從事相對應的操作(Commit/Rollback)。
- ⑤ 參與者收到 “Commit” 訊息後，則將Commit寫入系統日誌中，並真正更新資料庫的內容。若收到 “Rollback”，則針對自己的系統日誌從事回復 (Recovery)的動作。

# 圖示



## ■ 失敗處理：

- 一般而言，系統於準備階段發生失敗，表示所有參與者尚未完全將紀錄寫入日誌，通常需要將交易Rollback。若於行動階段失敗，表示交易已成功執行完畢並寫入日誌，可被復原 (Recovery)並確認 (Commit)交易。
- 系統協調者會將每個階段所作的動作紀錄於協調者本身的系統日誌中。若系統(協調者)失敗後重新啟動，可搜尋協調者的日誌內容：
  - 找到失敗的地方以及狀態，並繼續進行。(如：收到所有參與者的OK/Not OK，但來不及發出訊息即掛掉時)
  - 若找不到協調者的日誌內容，則假設為Rollback。(如：未收到所有參與者的OK/Not OK即掛掉時)
- 一般採用延遲更新技術。
  - ∵分散式環境風險高。