Transaction, répartition, et cohérence

- **Répartition des données et Réplication de données et Architecture**
- **Niveaux de cohérence**
- **Propriétés ACID et gestion des conflits**
- **Théorème de CAP**

©Maude Manouvrier - Univ. Paris-Dauphine

Passage à l'échelle (*Scalability/Elasticity*)

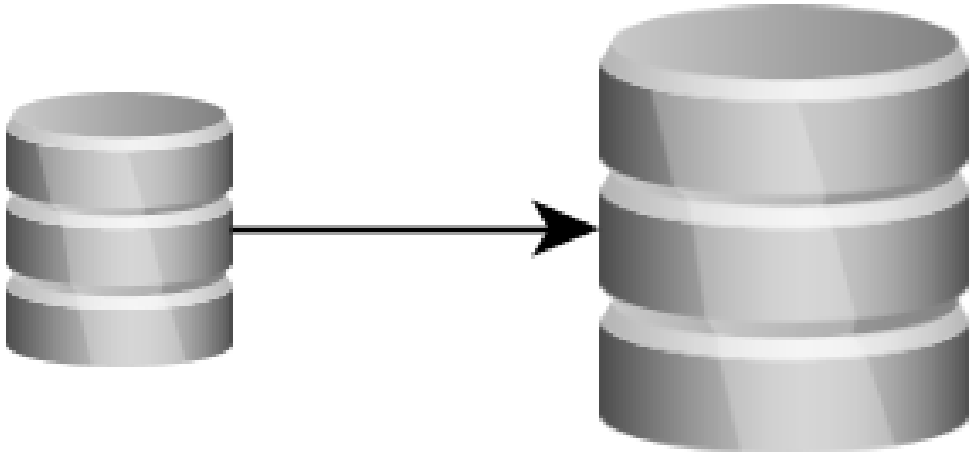

Vertical

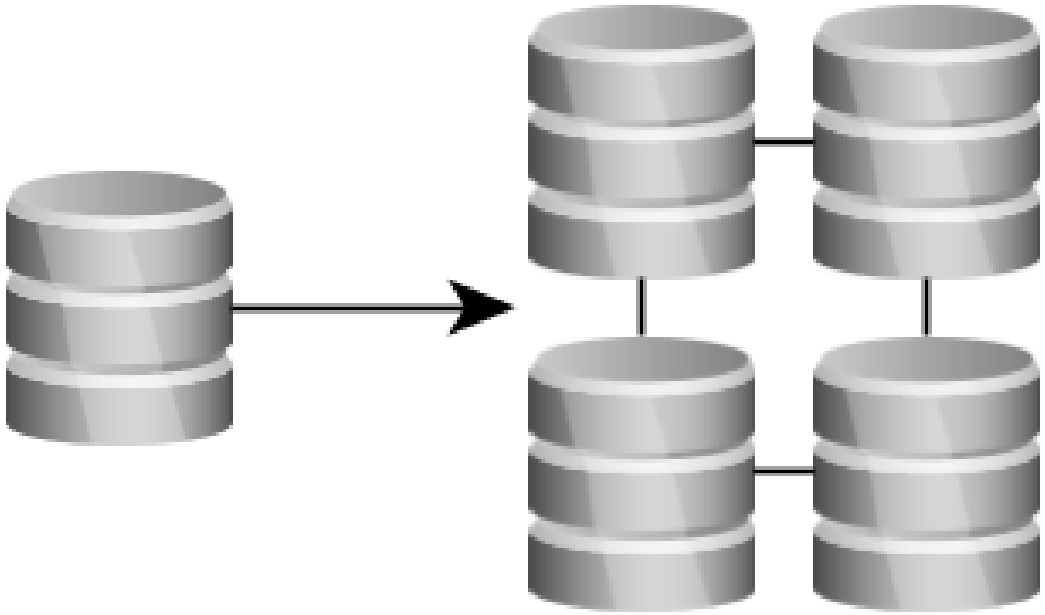

Horizontal

©Maude Manouvrier - Univ. Paris-Dauphine – repris de https://blog.philipphauer.de/relational-databases-strength-weaknesses-mongodb/

Répartition des données et réplication

- **Partitionnement (*sharding*)**
  Différentes données réparties sur différents nœuds

- **Réplication**
  Copie d'une même donnée sur différents nœuds

Partitionnement (*sharding*)

Données réparties sur différents nœuds

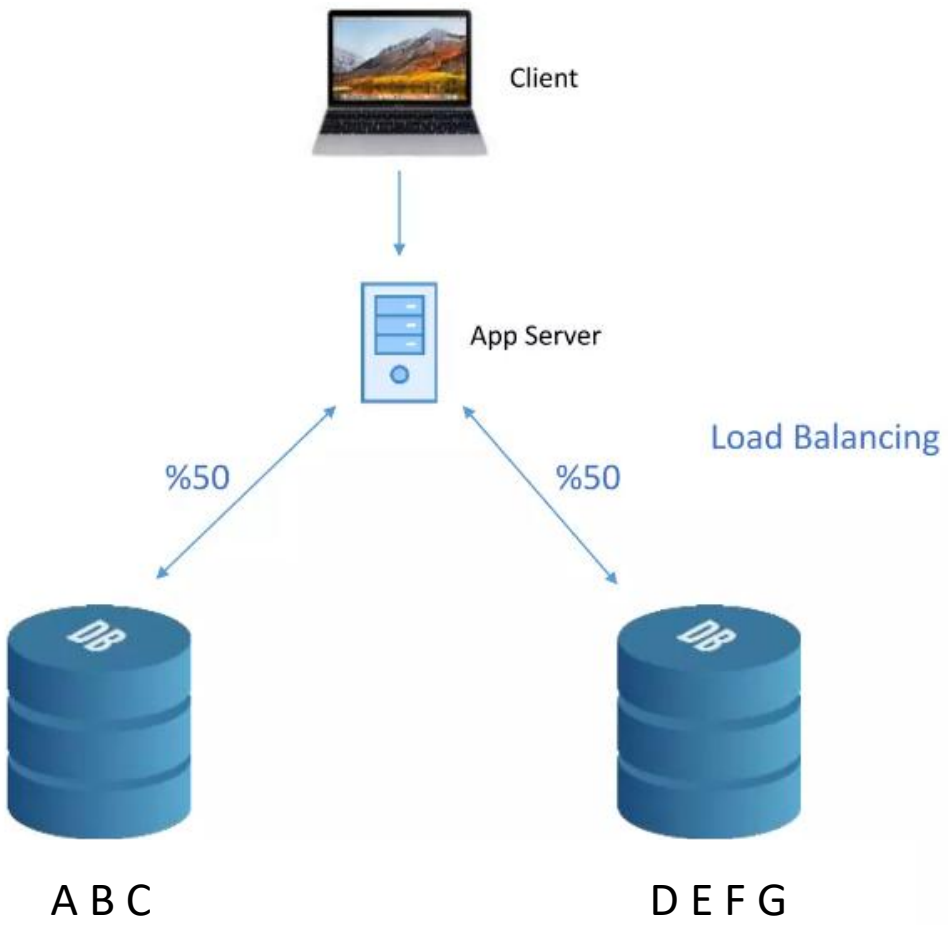

Réplication

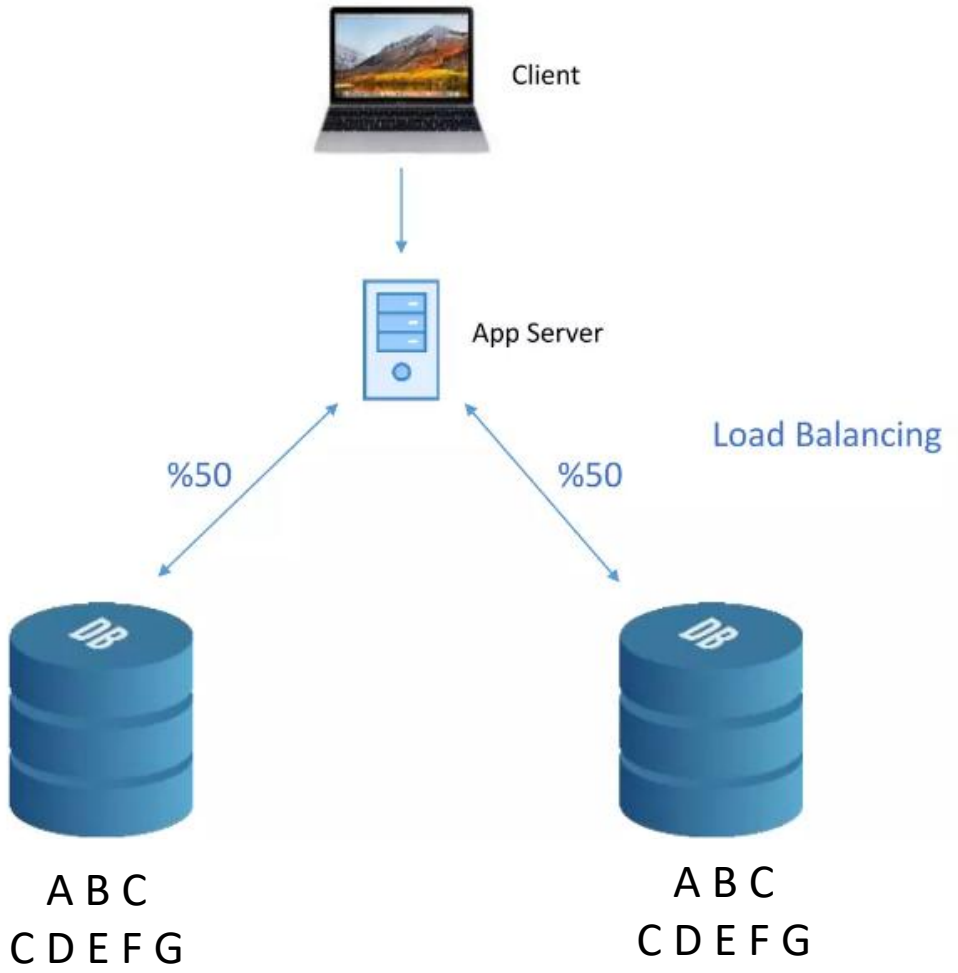

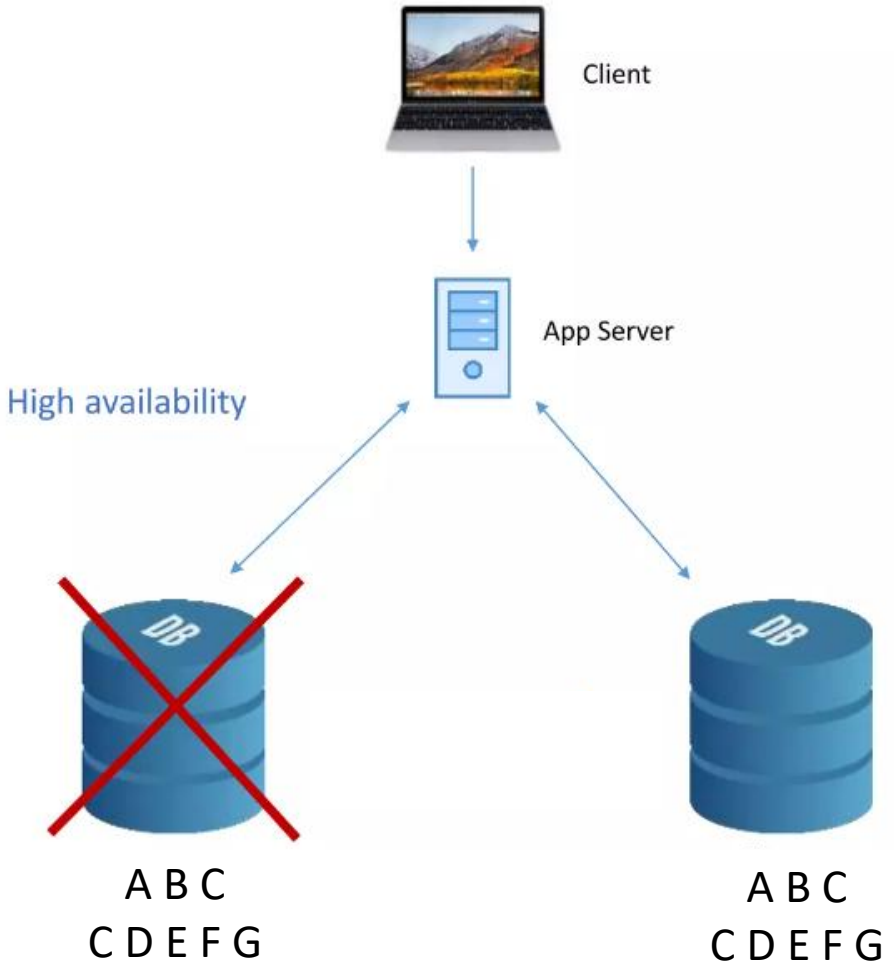

Sharding

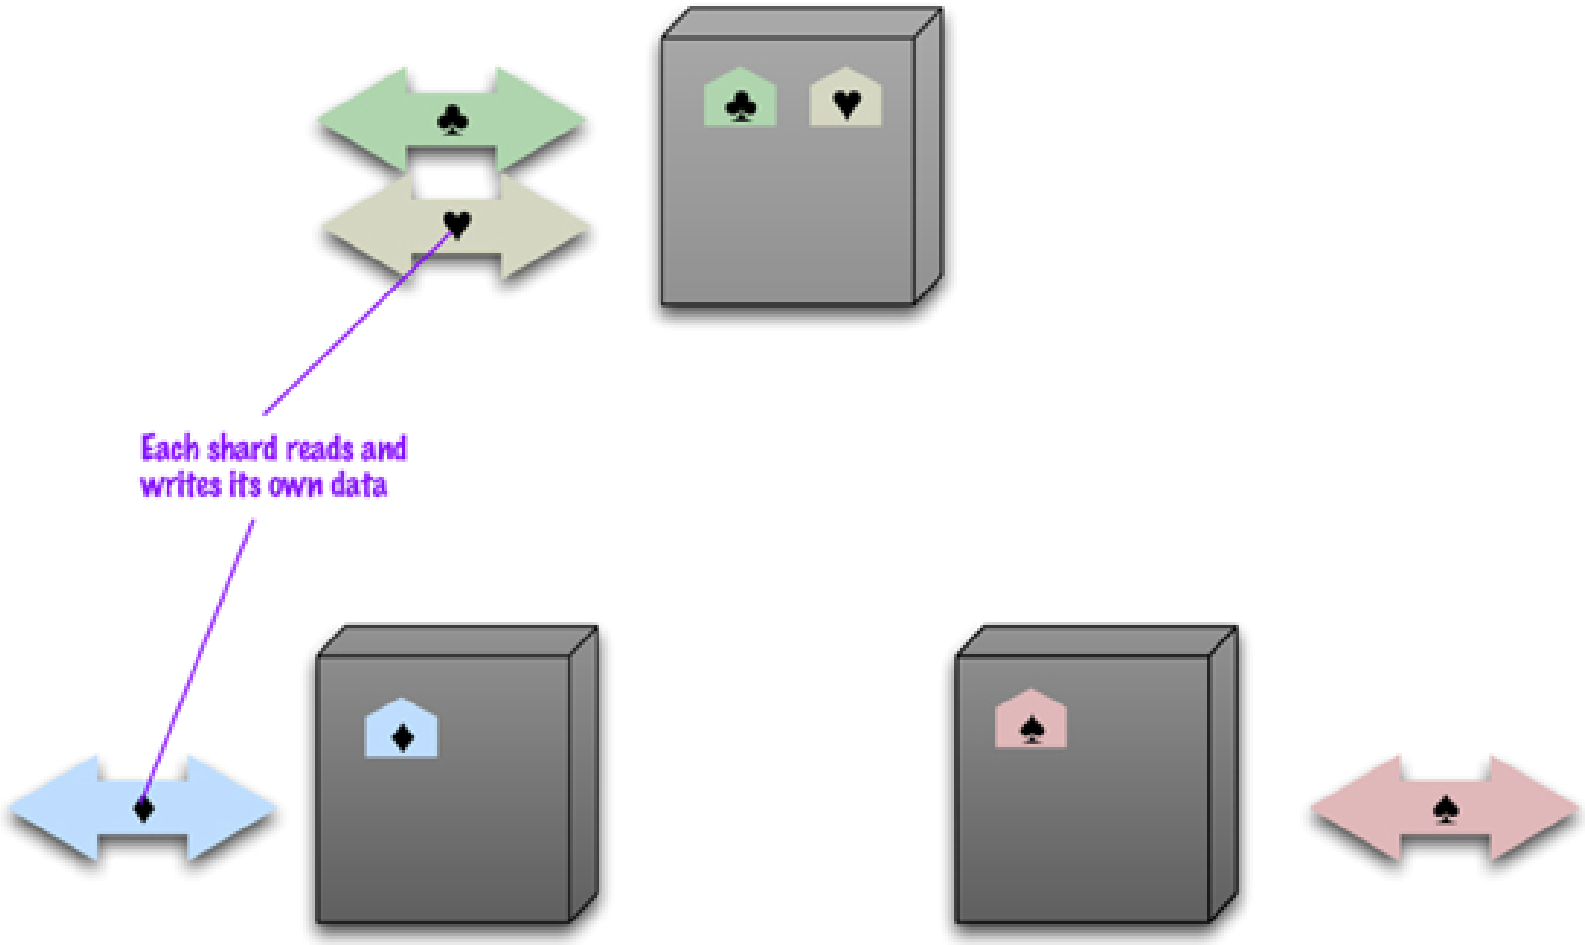

Figure 4.1. Sharding puts different data on separate nodes, each of which does its own reads and writes.

Partitionnement

- **Vertical :** différentes tables ou colonnes réparties sur différents serveurs
- **Horizontal** : chaque serveur est responsable d'un sous ensemble de données (identifié par un intervalle de clés)

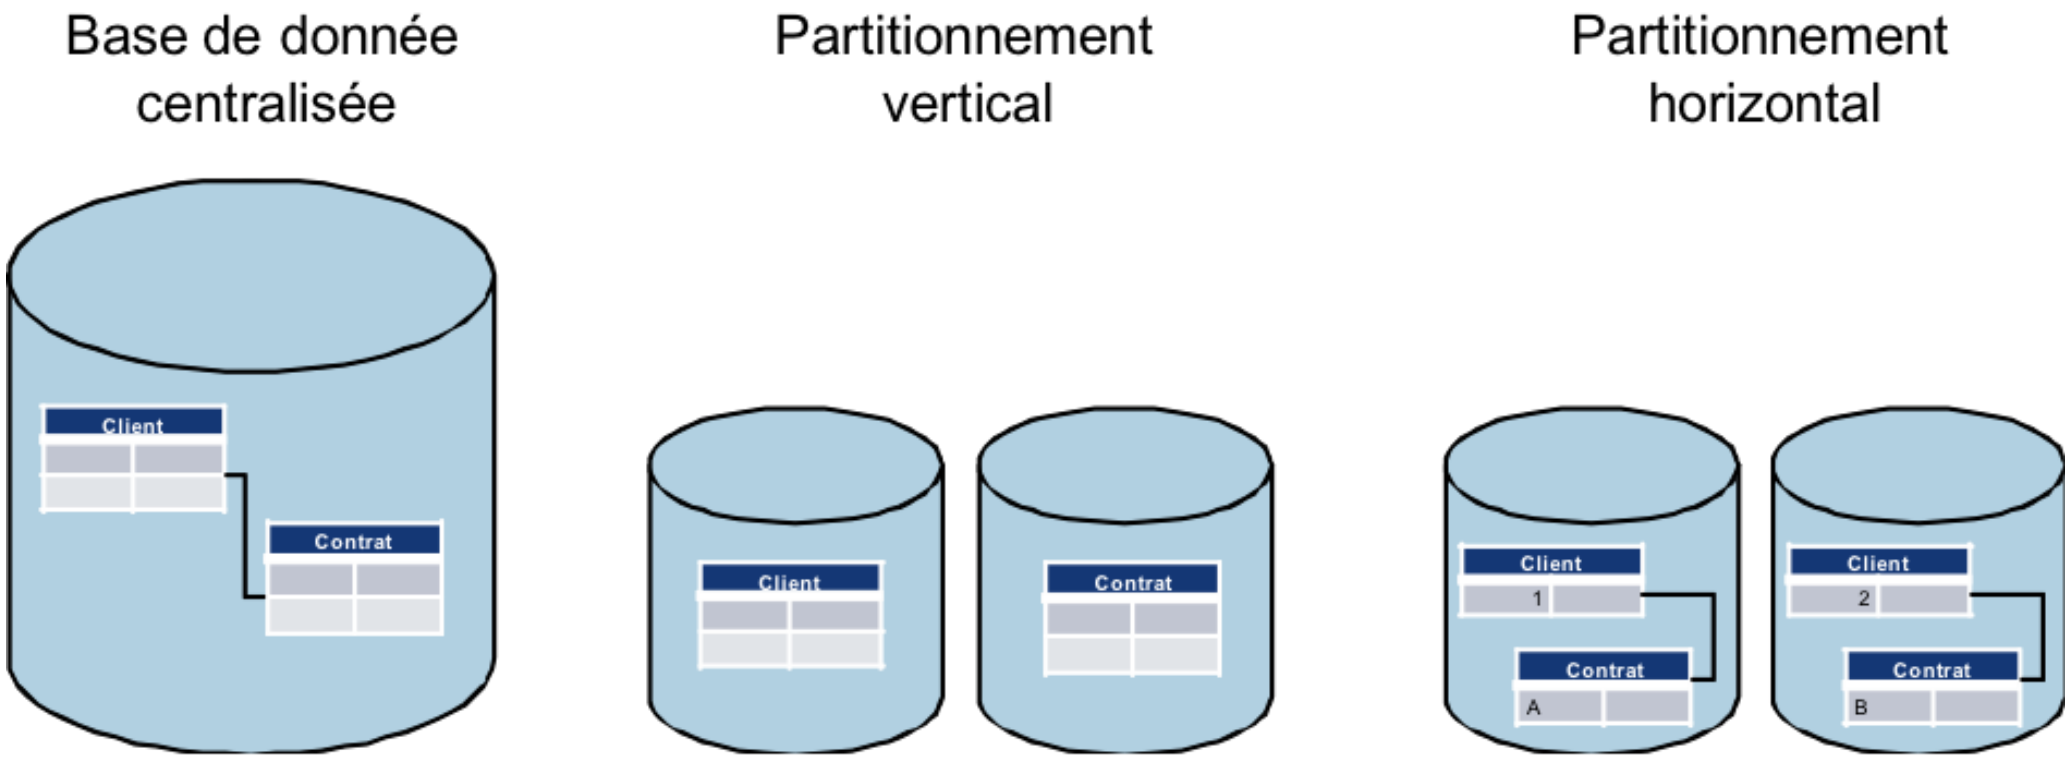

Partitionnement horizontale / vertical

Clé	Nom	Description	Stock	Prix	Dernière commande
ARC1	Arc welder	250Amps	8	119.00	25-Nov-2013
BRK8	Bracket	250mm	46	5.66	18-Nov-2013
BRK9	Bracket	400mm	82	6.98	1-Jul-2013
HOS8	Hose	1/2"	27	27.50	18-Aug-2013
WGT4	Widget	Green	16	13.99	3-Feb-2013
WGT6	Widget	Purple	76	13.99	31-Mar-2013

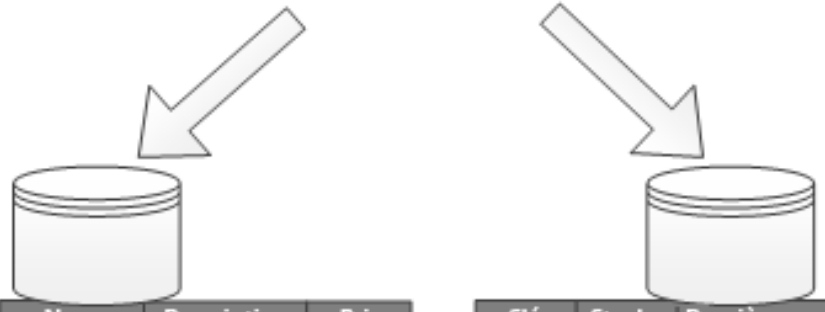

Clé	Nom	Description	Prix
ARC1	Arc welder	250Amps	119.00
BRK8	Bracket	250mm	5.66
BRK9	Bracket	400mm	6.98
HOS8	Hose	1/2"	27.50
WGT4	Widget	Green	13.99
WGT6	Widget	Purple	13.99

Clé	Stock	Dernière commande
ARC1	8	25-Nov-2013
BRK8	46	18-Nov-2013
BRK9	82	1-Jul-2013
HOS8	27	18-Aug-2013
WGT4	16	3-Feb-2013
WGT6	76	31-Mar-2013

Partitionnement vertical

Clé	Nom	Description	Stock	Prix	Dernière commande
ARC1	Soudeuse à arc	250 Amps	8	119.00	25-nov-2013
BRK8	Support	250mm	46	5.66	18-nov-2013
BRK9	Support	400mm	82	6.98	1-juil-2013
HOS8	Tuyau	1/2"	27	27.50	18-août-2013
WGT4	Widget	Green	16	13.99	3-fév-2013
WGT6	Widget	Purple	76	13.99	31-mar-2013

Clé	Nom	Description	Stock	Prix	Dernière commande
ARC1	Soudeuse à arc	250 Amps	8	119.00	25-nov-2013
BRK8	Support	250mm	46	5.66	18-nov-2013
BRK9	Support	400mm	82	6.98	1-juil-2013

Clé	Nom	Description	Stock	Prix	Dernière commande
HOS8	Tuyau	1/2"	27	27.50	18-août-2013
WGT4	Widget	Green	16	13.99	3-fév-2013
WGT6	Widget	Purple	76	13.99	31-mar-2013

Partitionnement horizontal

©Maude Manouvrier - Univ. Paris-Dauphine – Figure reprise de https://blog.octo.com/sharding/

Architecture Maître - Esclaves (1/5)

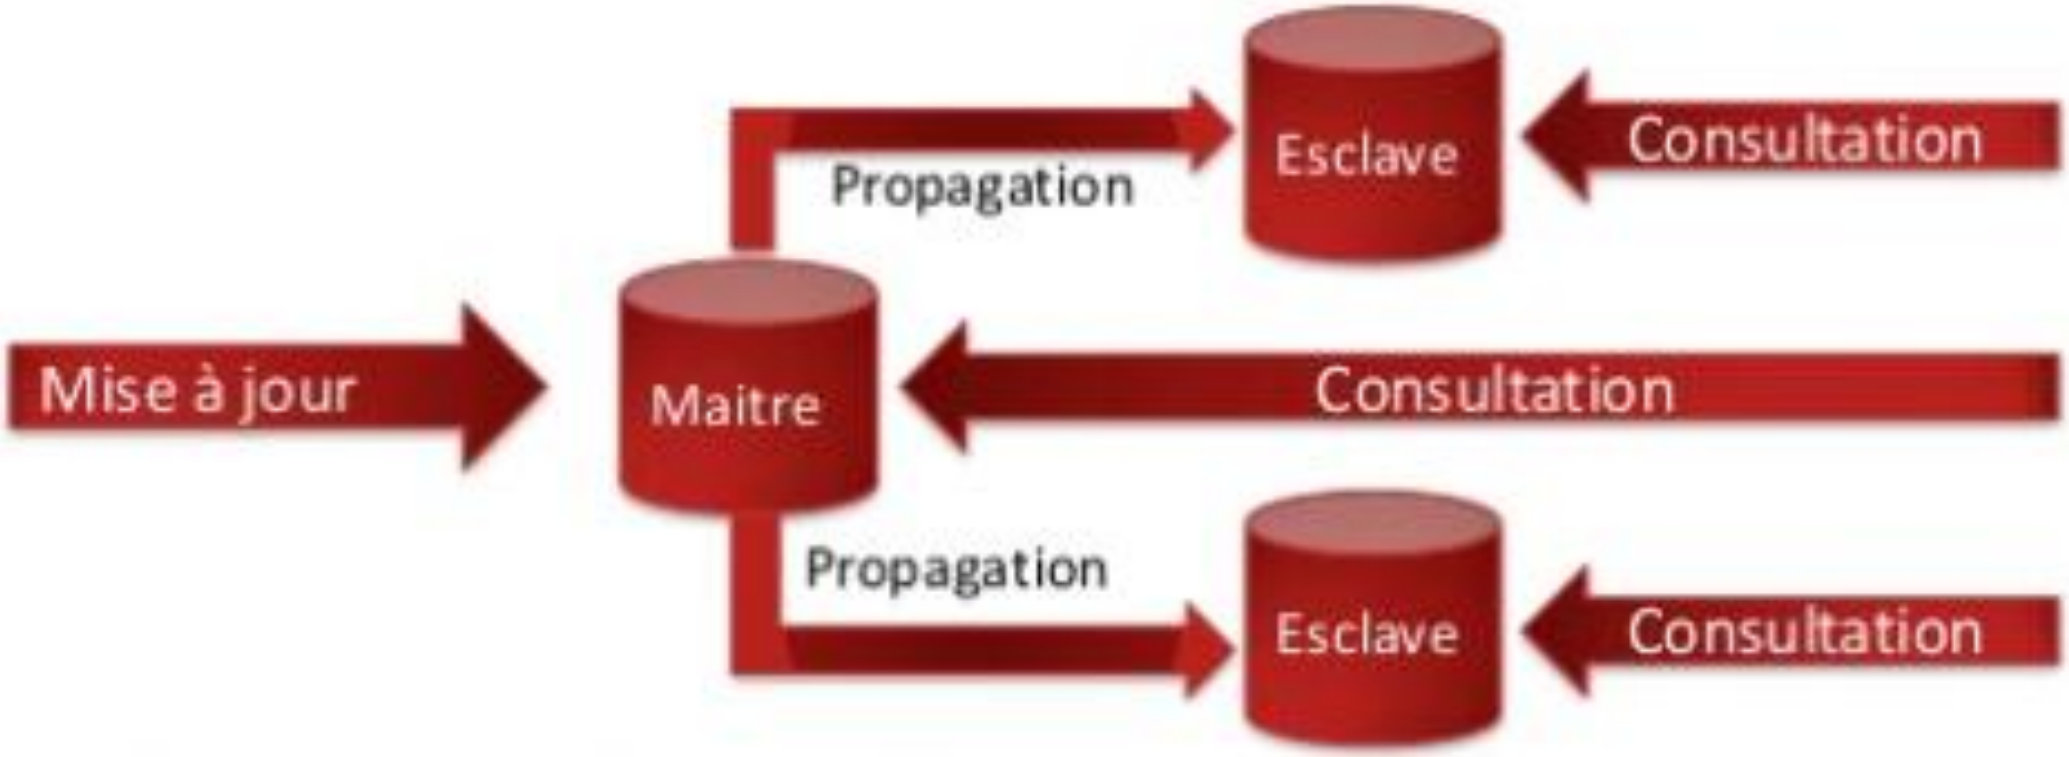

Maitre – Esclaves et Réplication

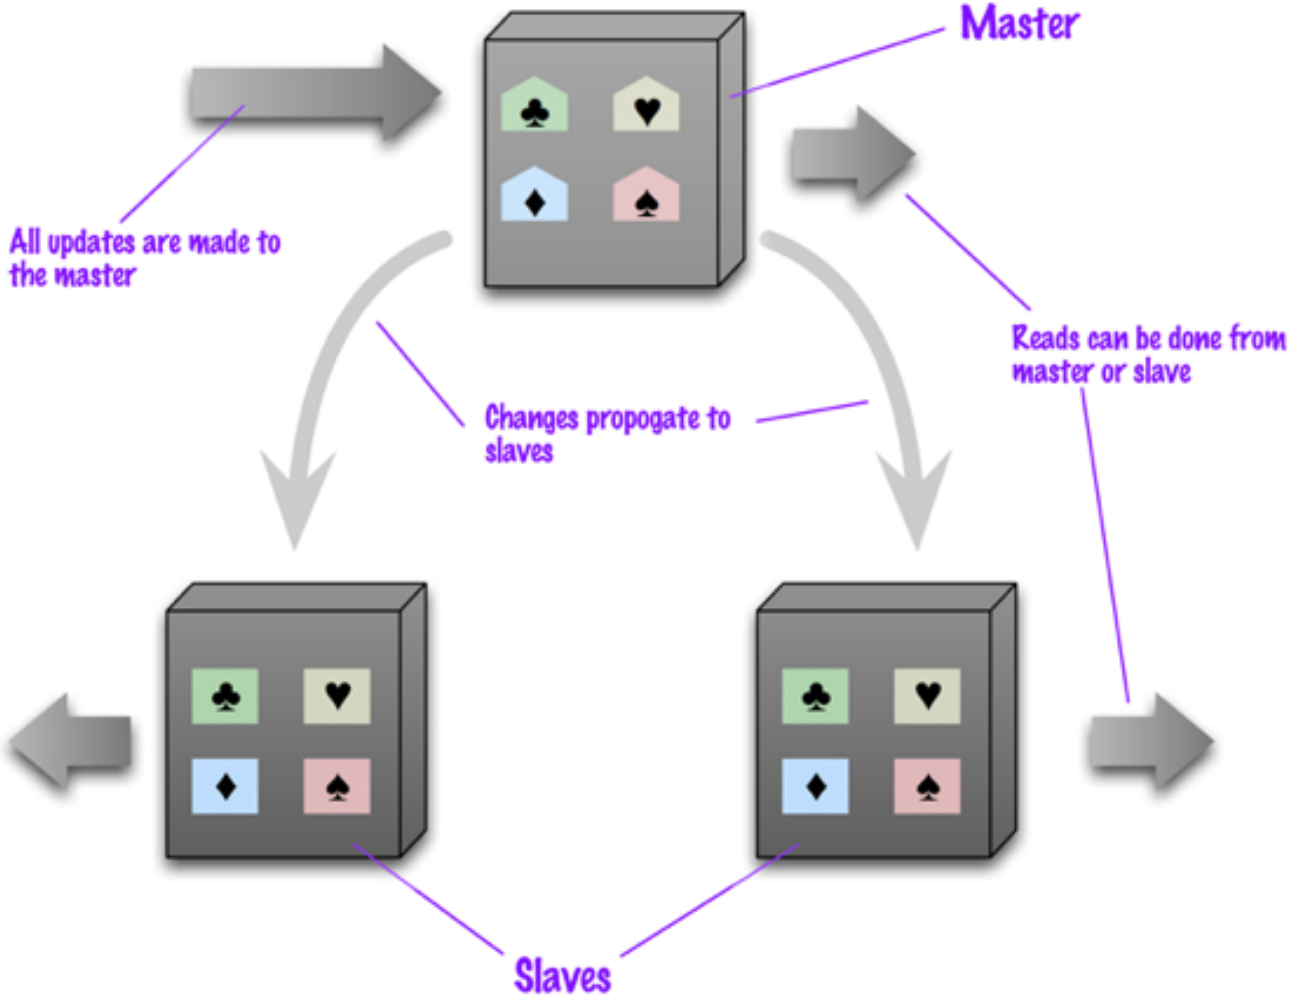

Figure 4.2. Data is replicated from master to slaves. The master services all writes; reads may come from either master or slaves.

Architecture Maître – Esclave (2/5)

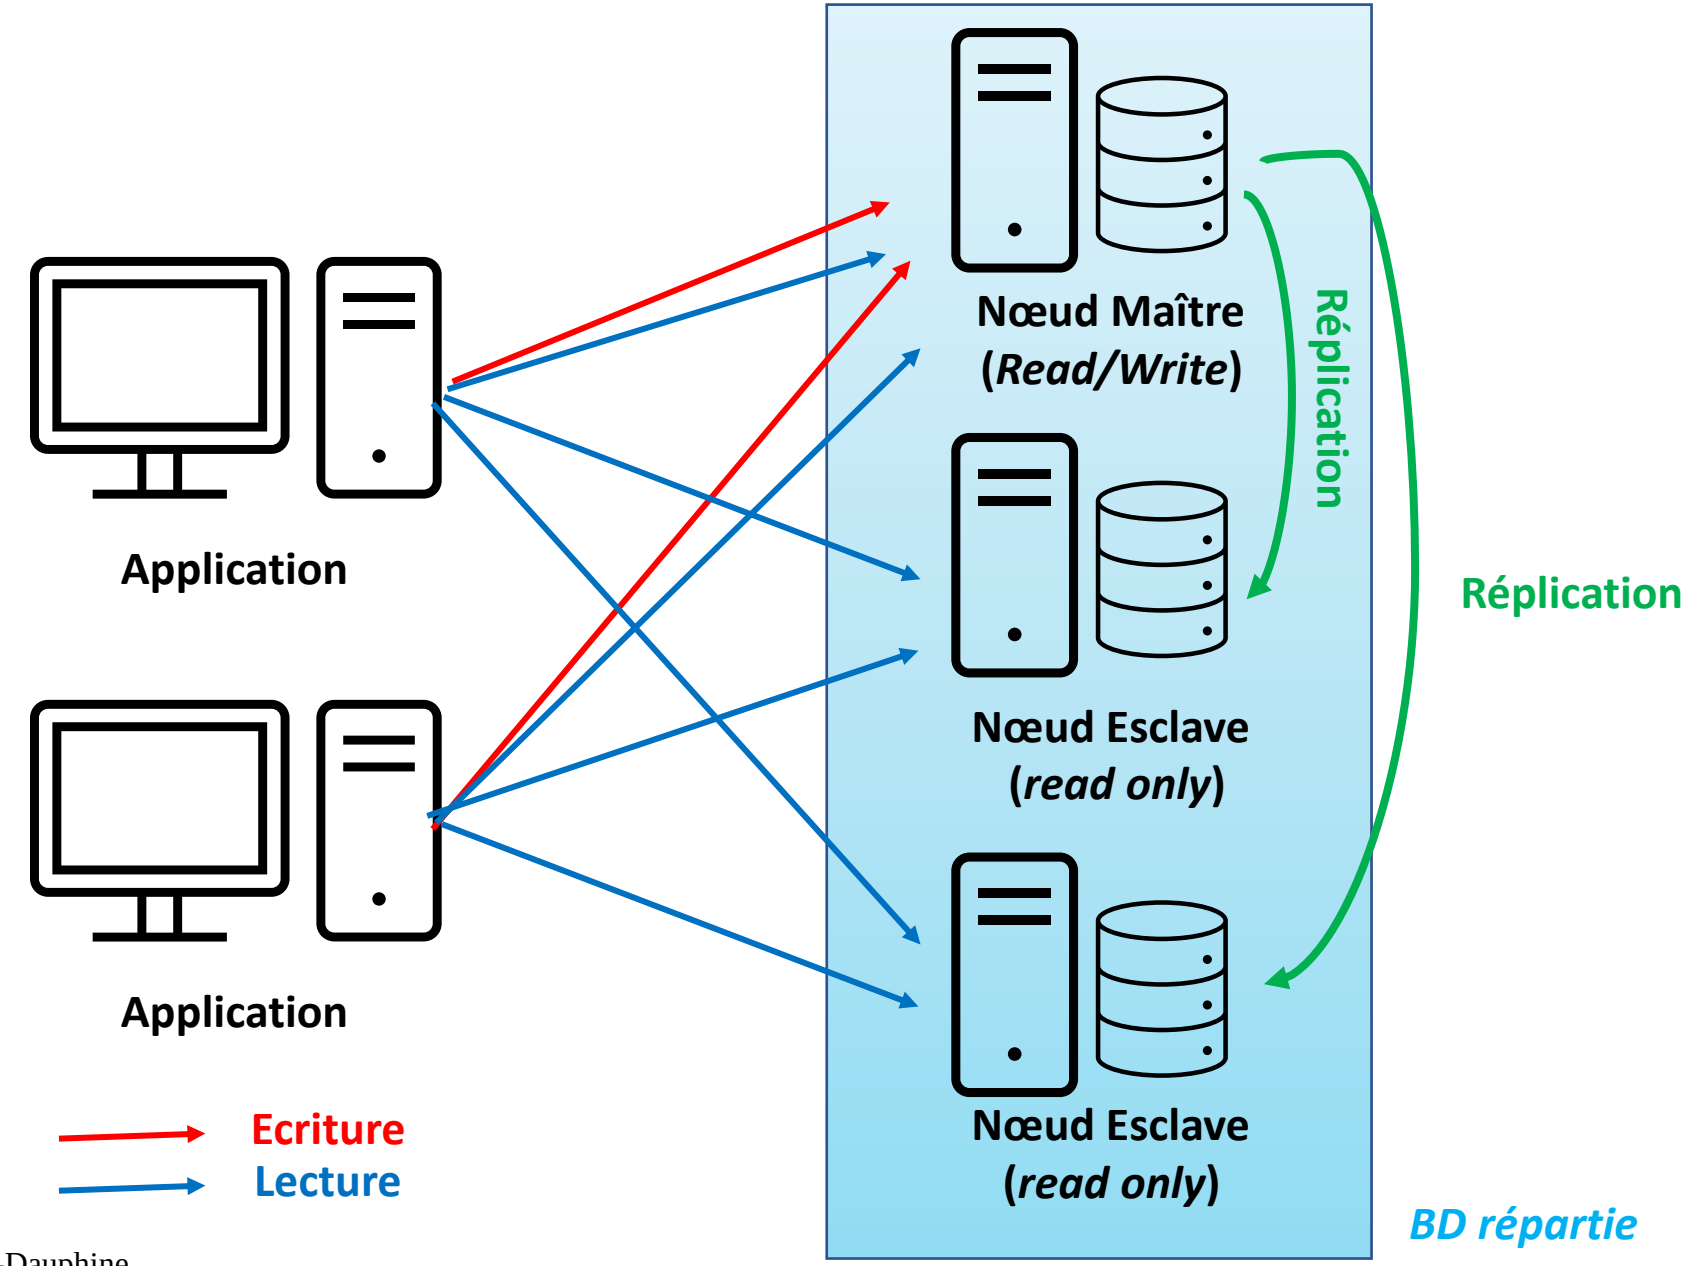

Architecture Maître - Esclave (3/5)

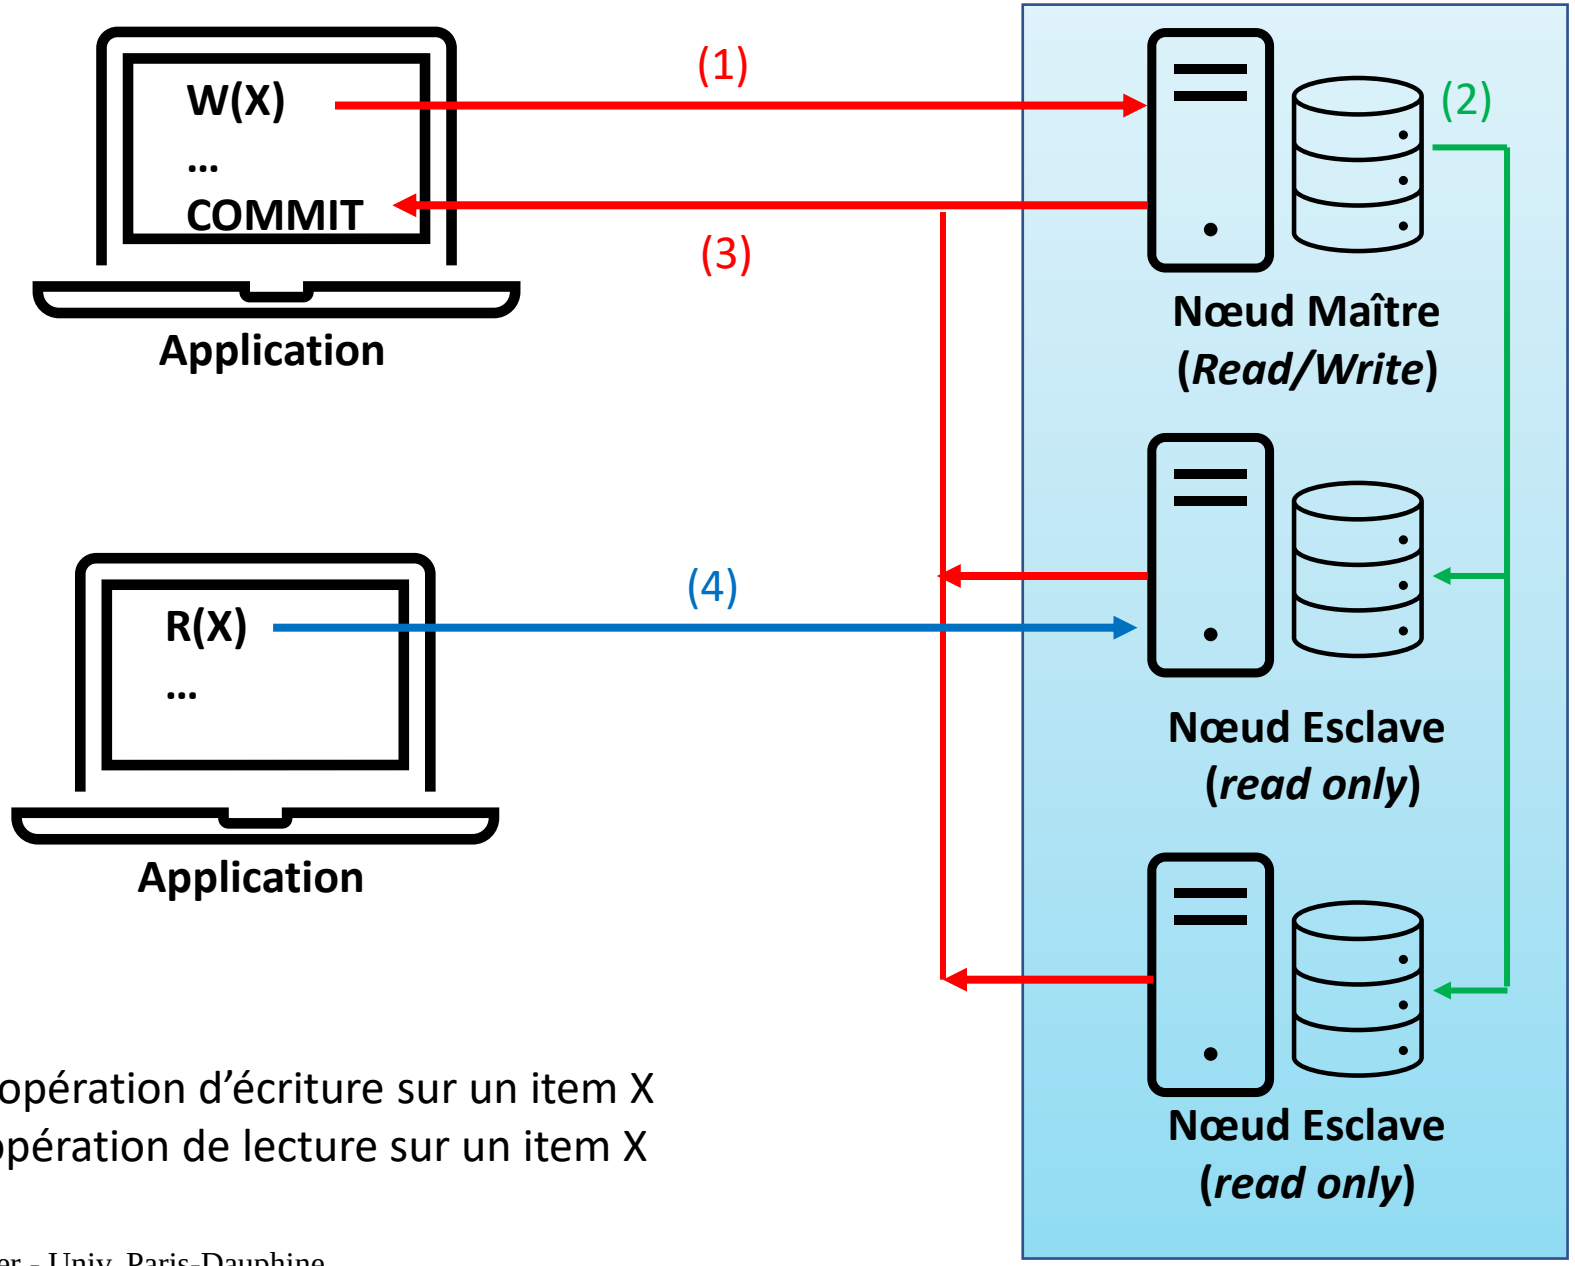

(1) Ecriture sur le Maître

(2) Réplication synchrone de l'écriture sur les esclaves

(3) Validation de l'écriture et acquittement au client

(4) Lecture depuis n'importe quel nœud

W(X) : opération d'écriture sur un item X
R(X) : opération de lecture sur un item X

©Maude Manouvrier - Univ. Paris-Dauphine

Architecture Maître - Esclave (4/5)

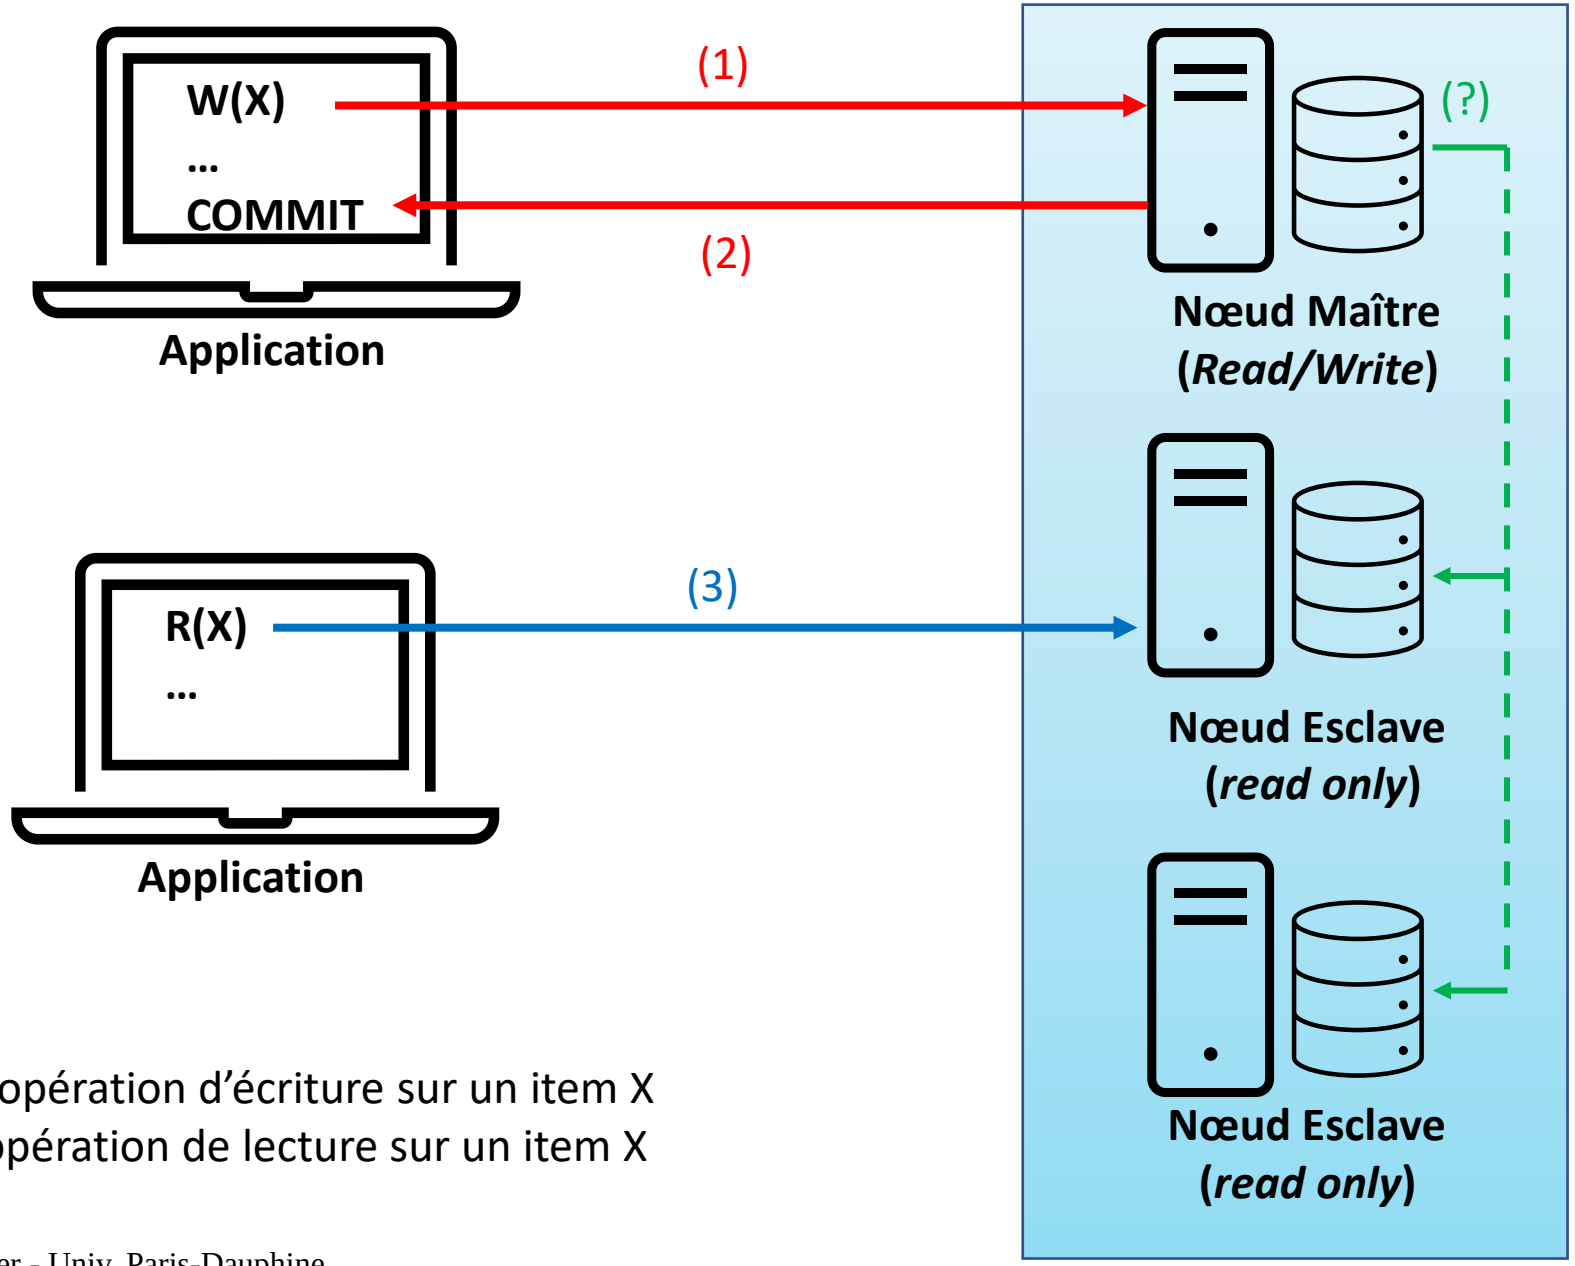

(1) Ecriture sur le Maître

(2) Validation de l'écriture et acquittement au client

(3) Lecture depuis n'importe quel nœud

(?) Réplication asynchrone de l'écriture sur les esclaves (cohérence à terme)

W(X) : opération d'écriture sur un item X
R(X) : opération de lecture sur un item X

©Maude Manouvrier - Univ. Paris-Dauphine

Architecture Maître – Esclave (5/5)

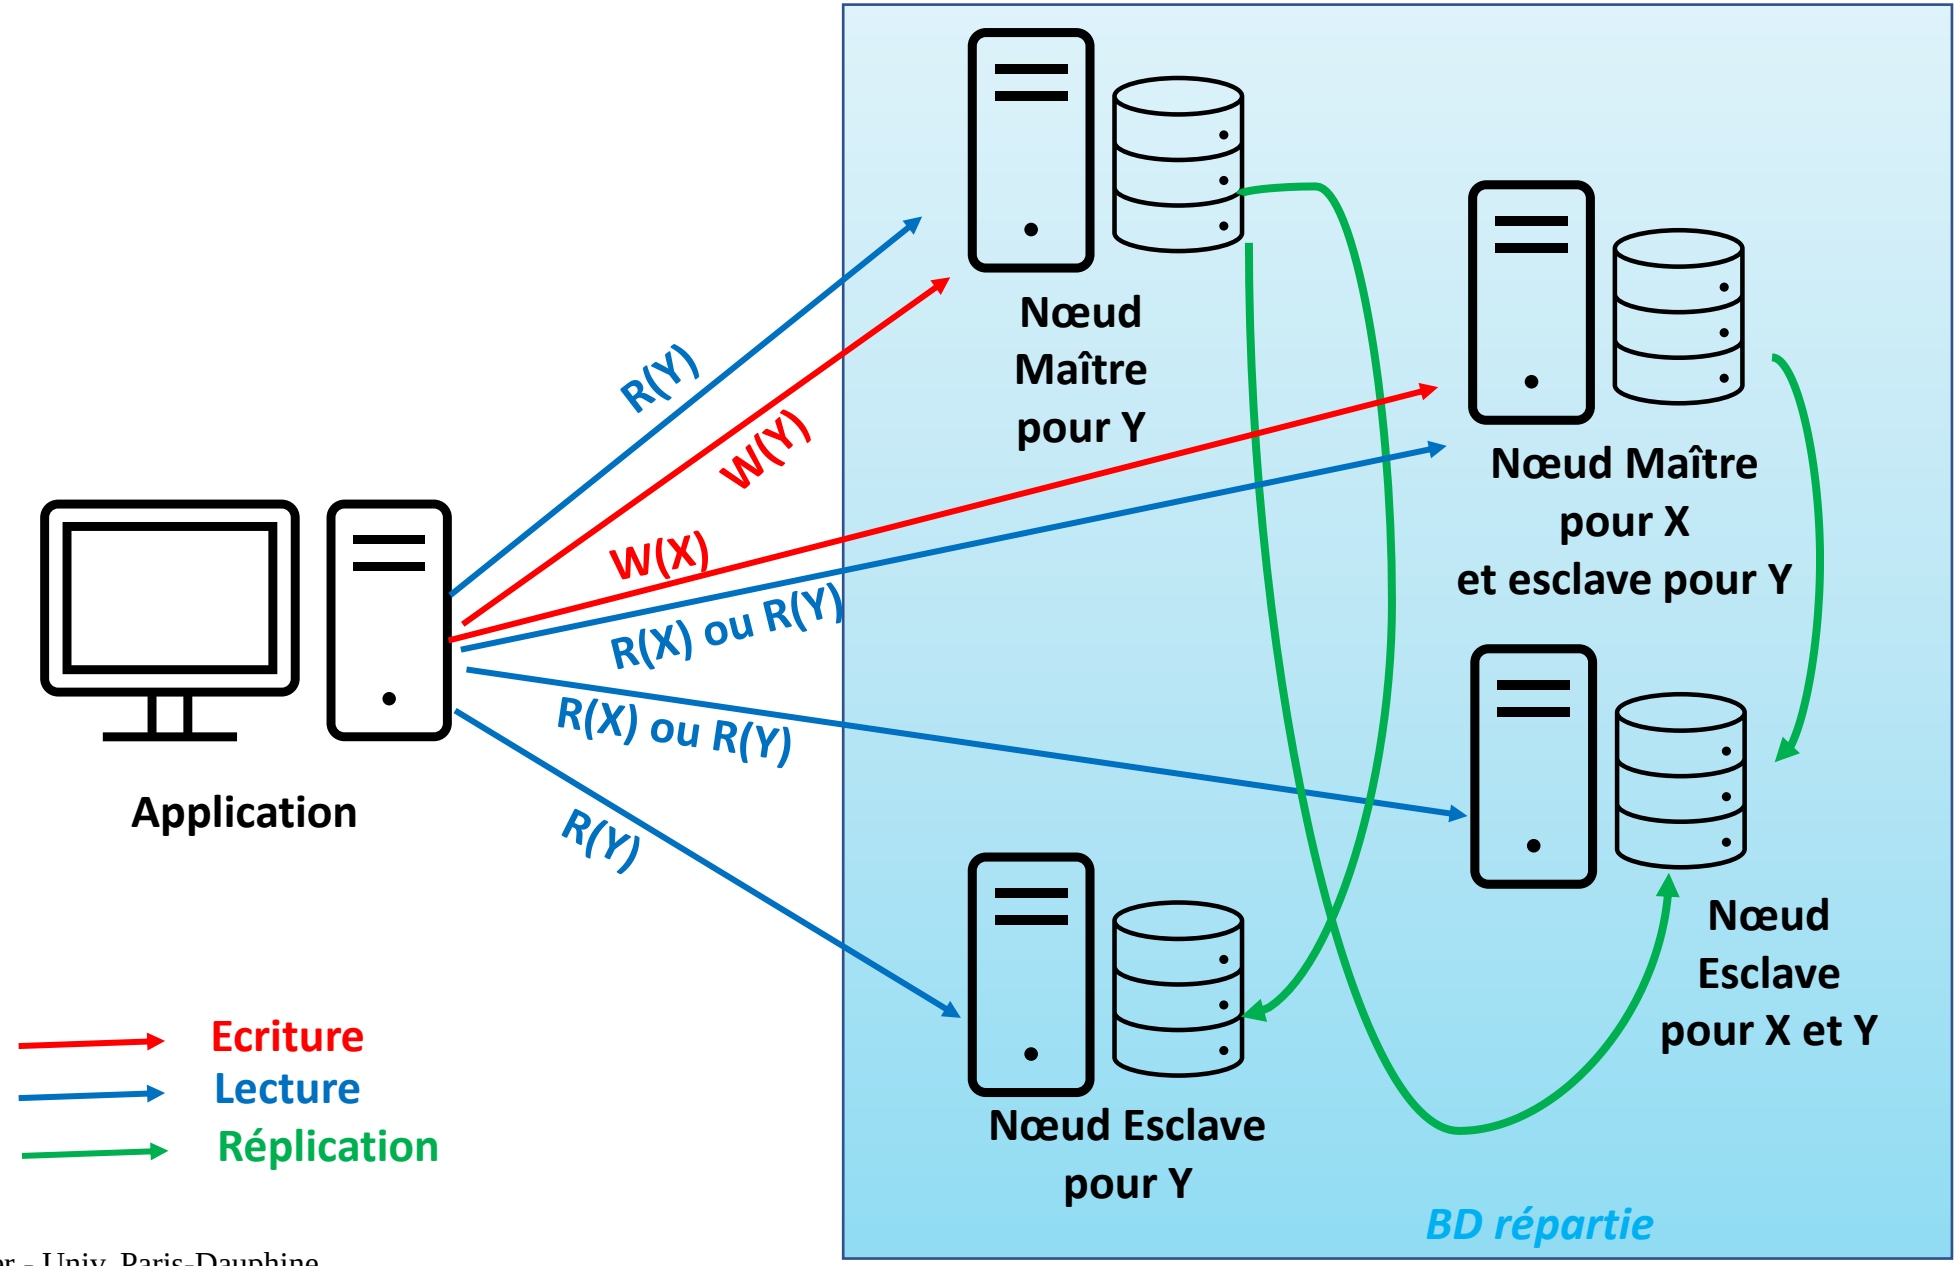

©Maude Manouvrier - Univ. Paris-Dauphine

Partitionnement et Réplication : maître -esclaves

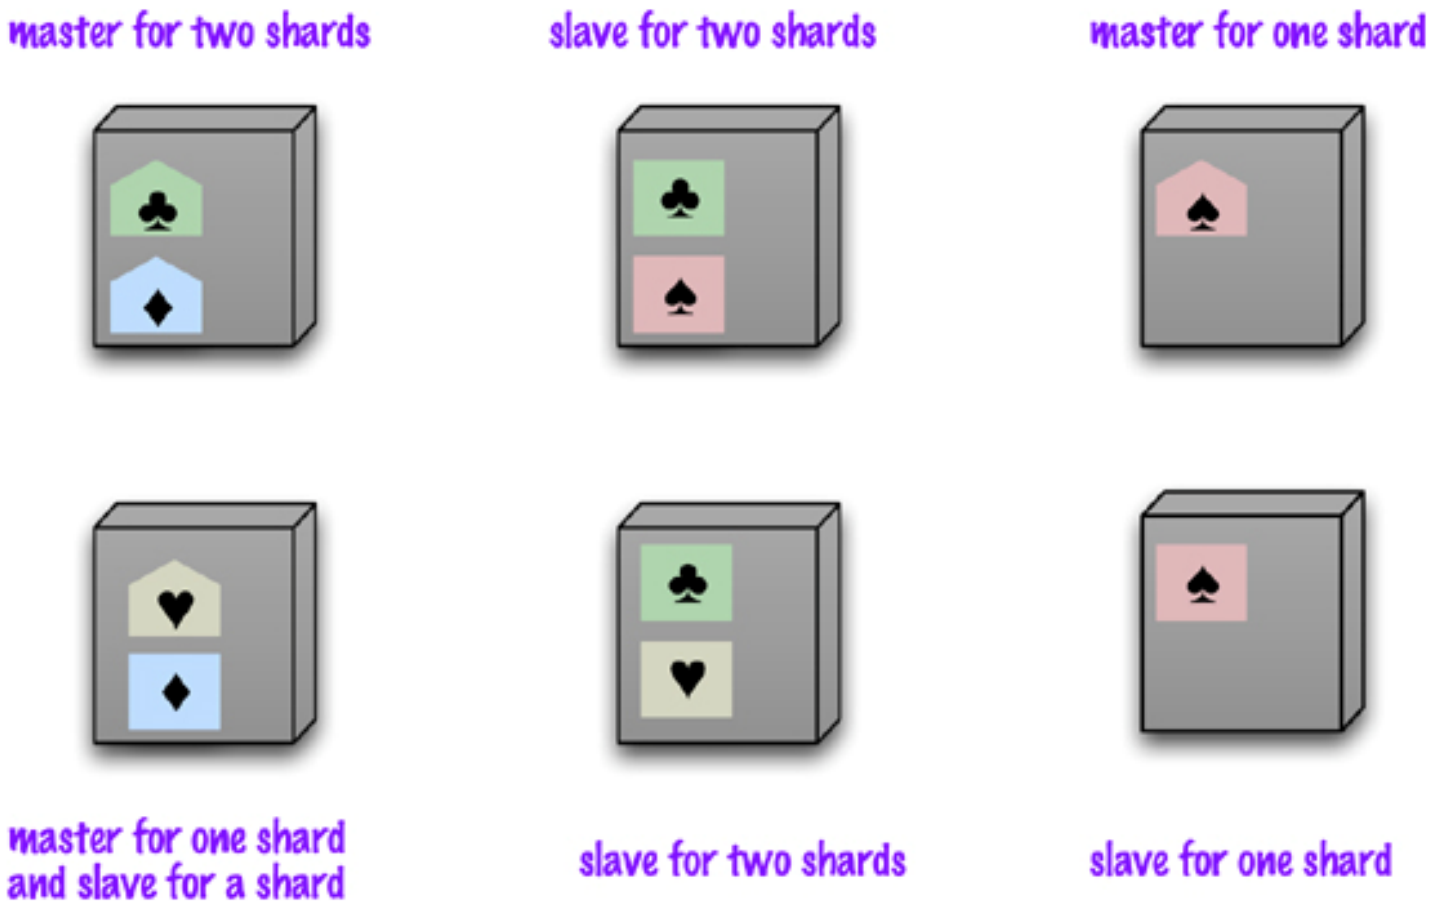

Figure 4.4. Using master-slave replication together with sharding

Architecture Pair à Pair (1/2)

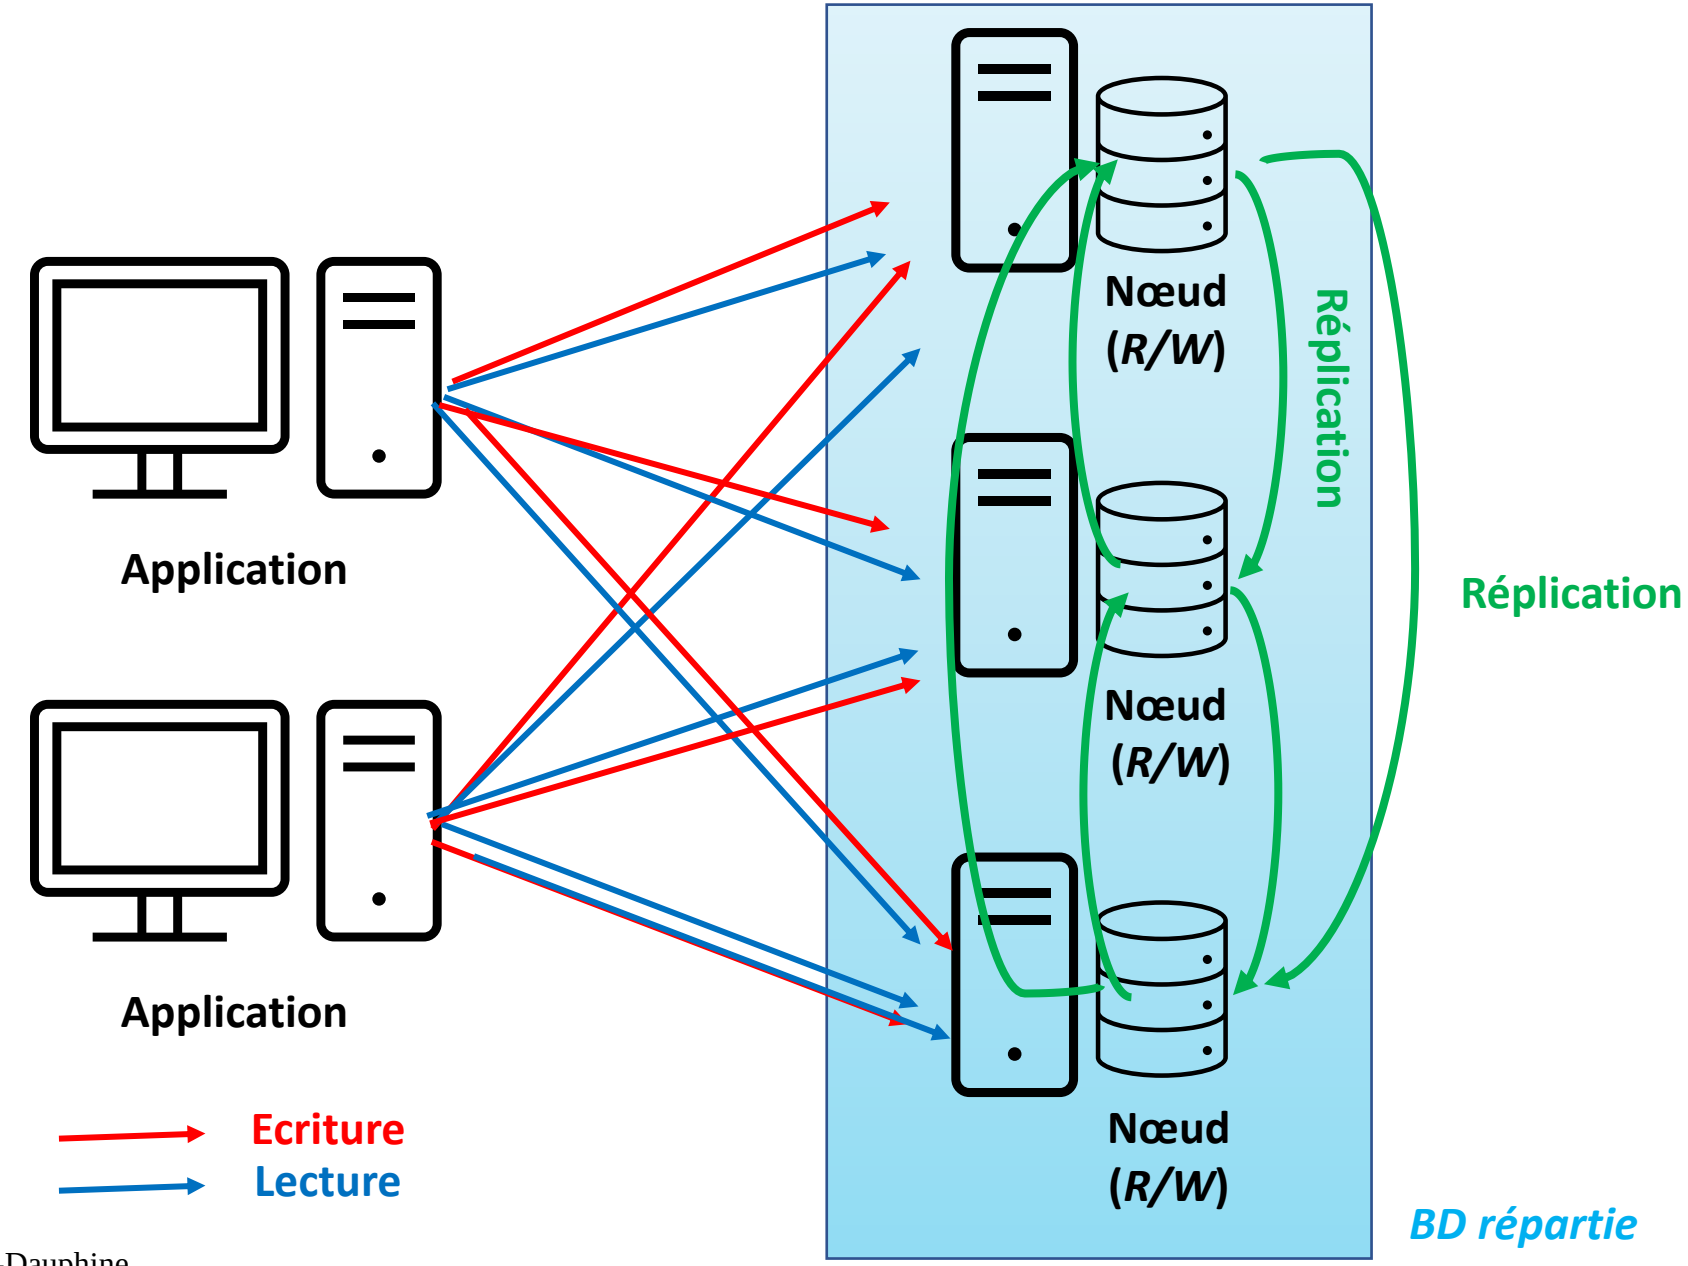

©Maude Manouvrier - Univ. Paris-Dauphine

Architecture Pair à Pair(2/2)

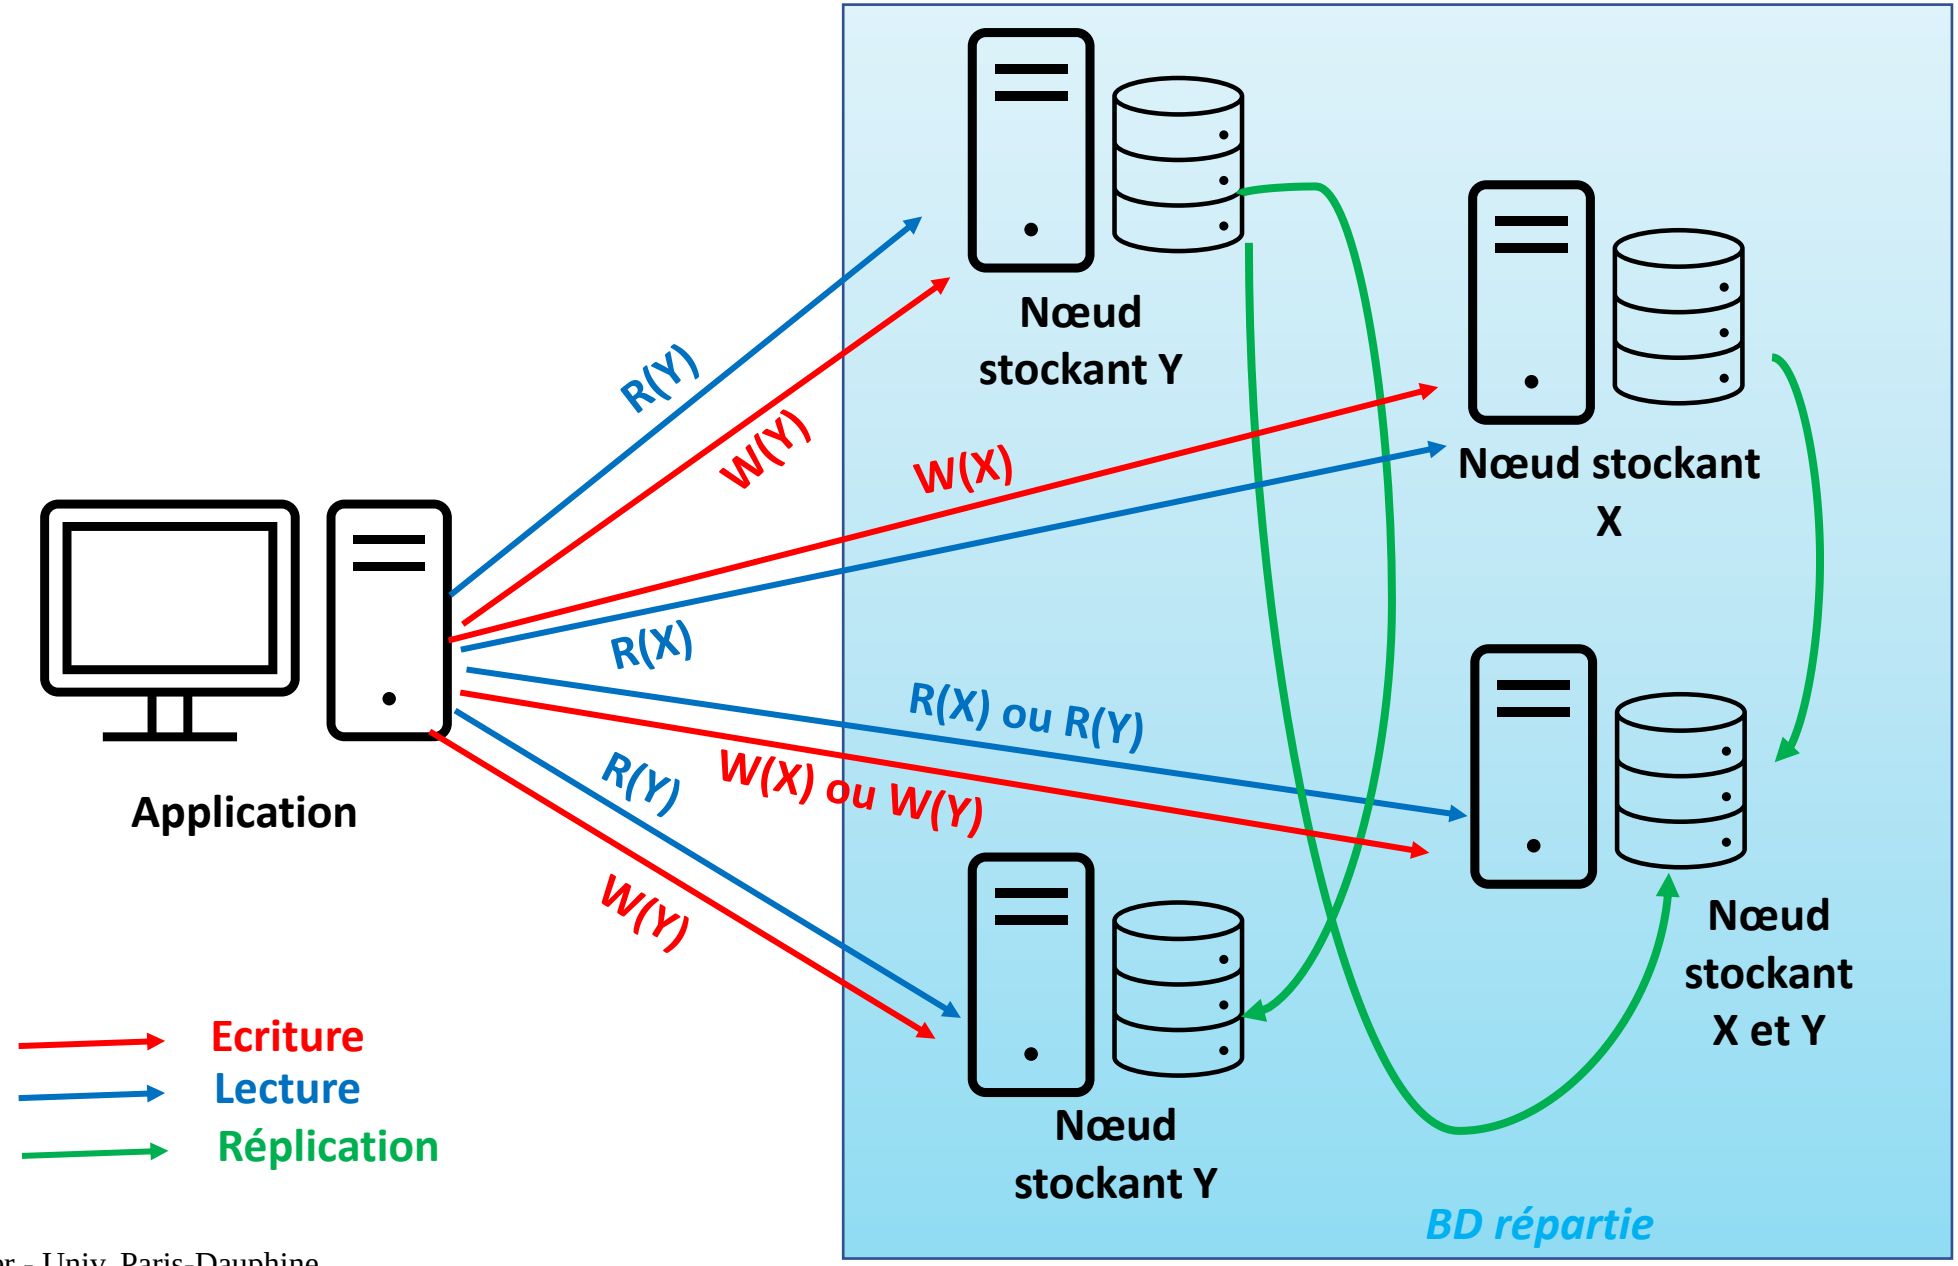

©Maude Manouvrier - Univ. Paris-Dauphine

Réplication *peer-to-peer*

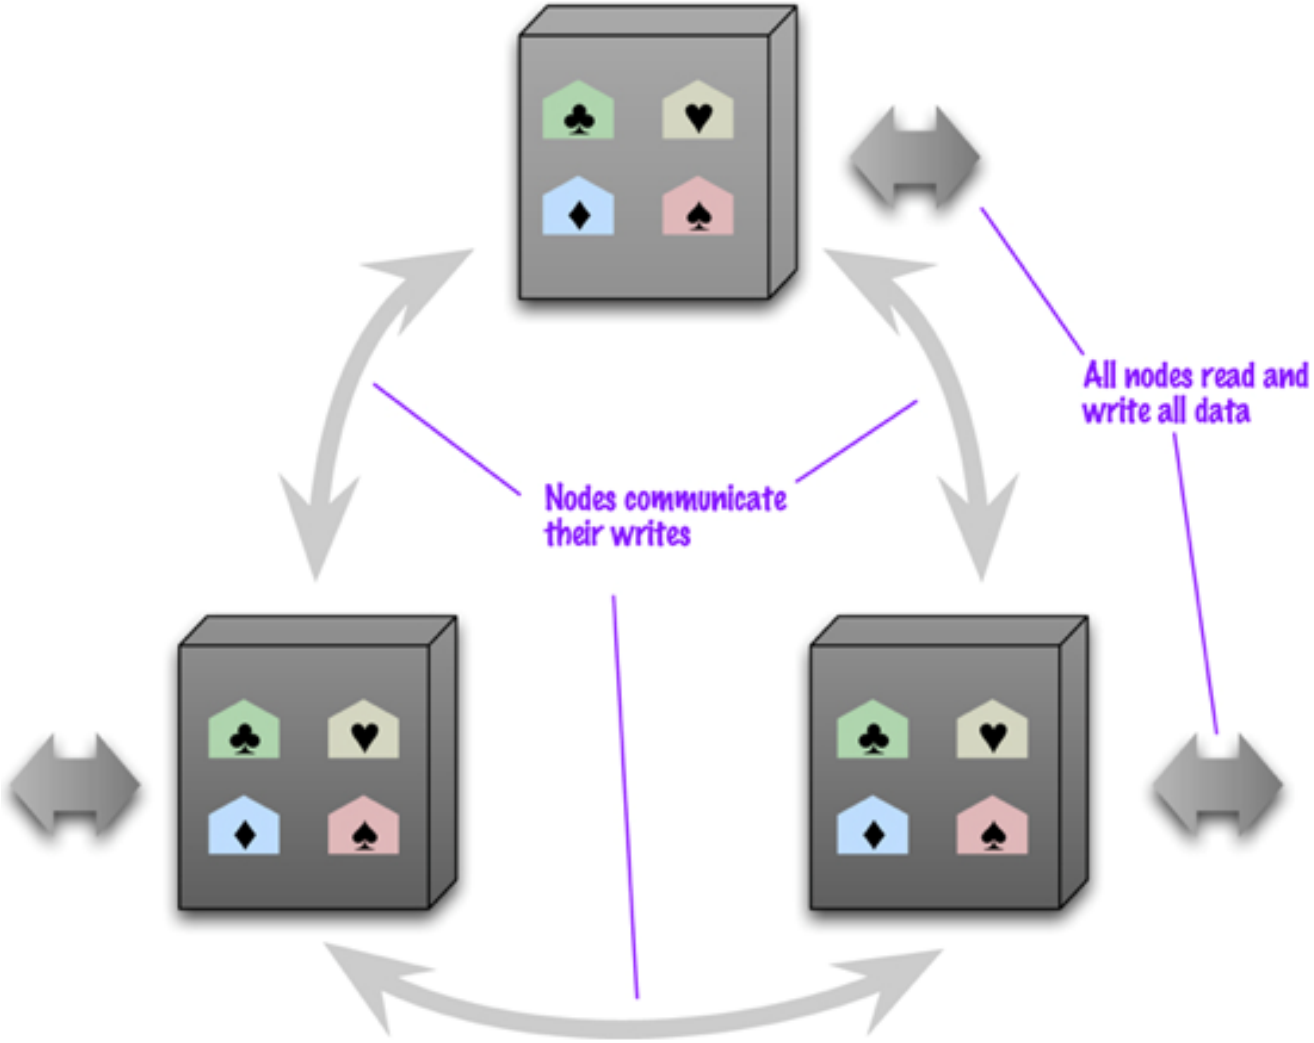

Figure 4.3. Peer-to-peer replication has all nodes applying reads and writes to all the data.

Partitionnement et Réplication : *peer-to-peer*

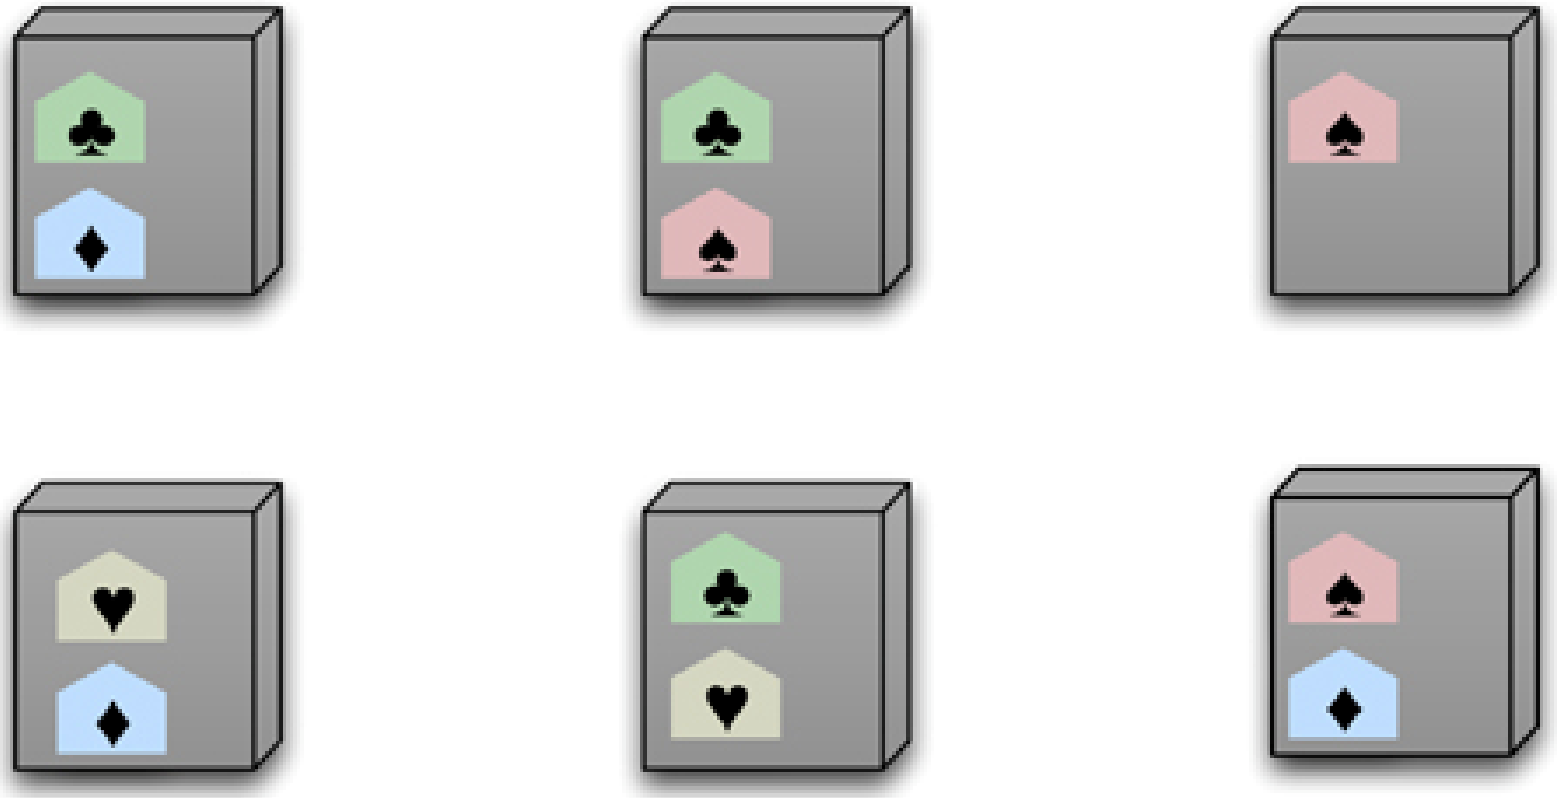

Figure 4.5. Using peer-to-peer replication together with sharding

©Maude Manouvrier - Univ. Paris-Dauphine – Figure reprise http://bigdata-ir.com/wp-content/uploads/2017/04/NoSQL-Distilled.pdf

Réplication synchrone / asynchrone

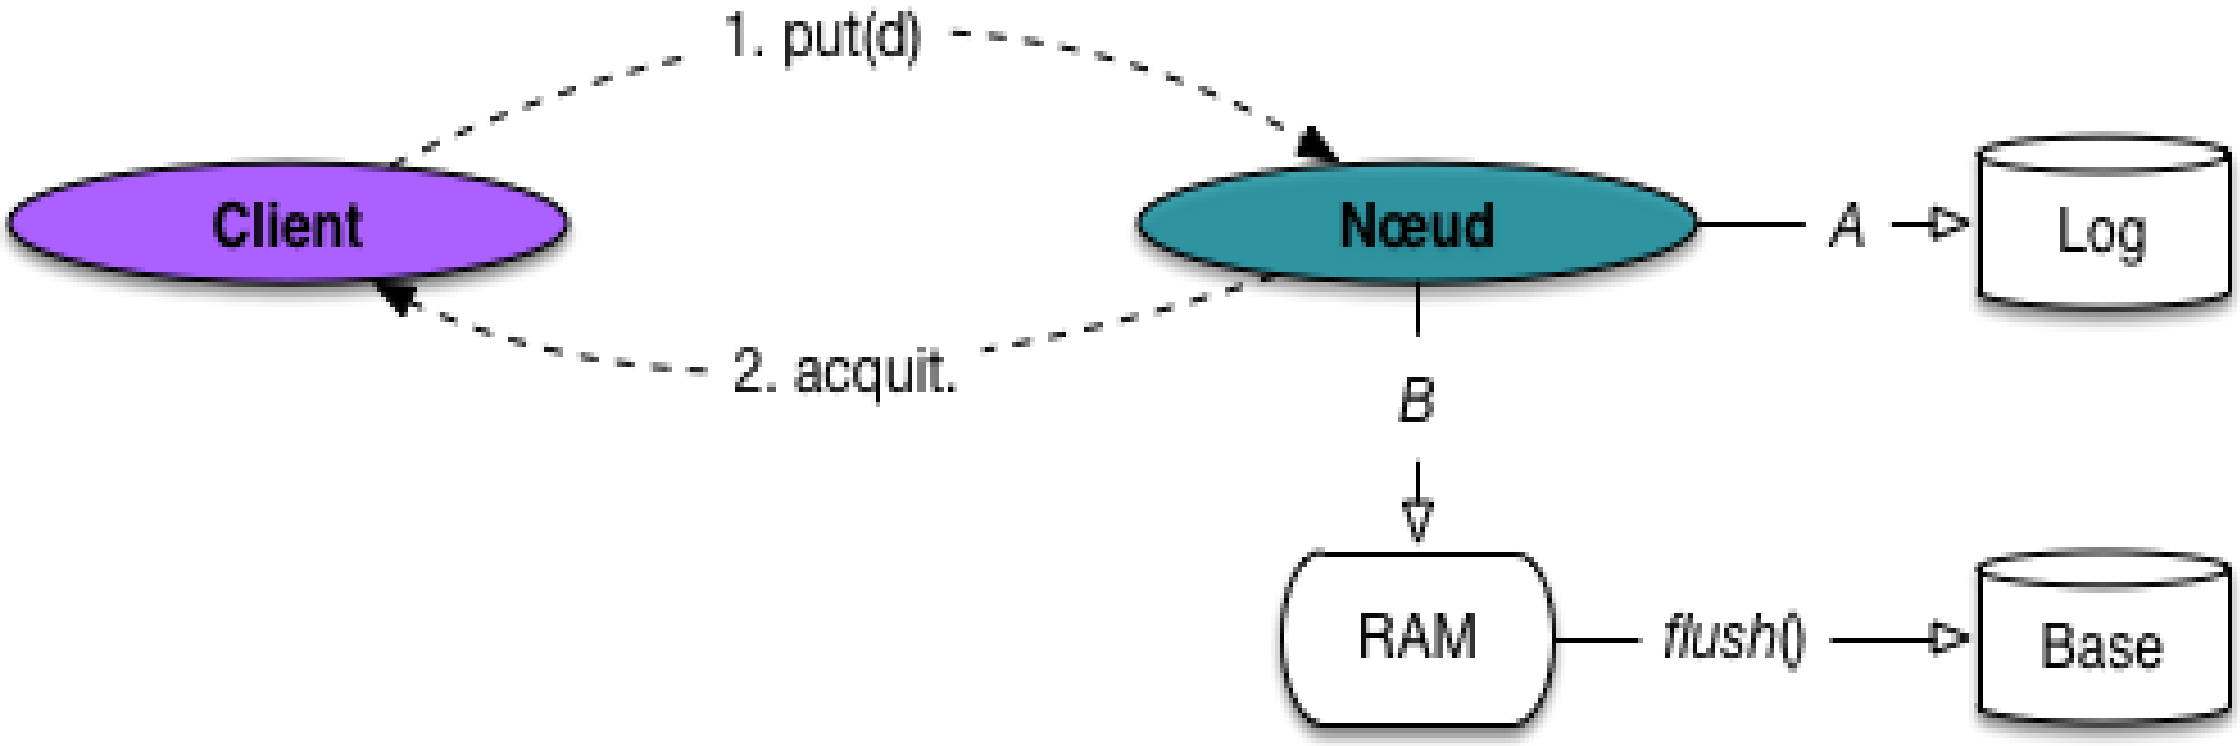

Ecriture avec journalisation

©Maude Manouvrier - Univ. Paris-Dauphine – Figure reprise http://b3d.bdpedia.fr/replication.html

Réplication synchrone

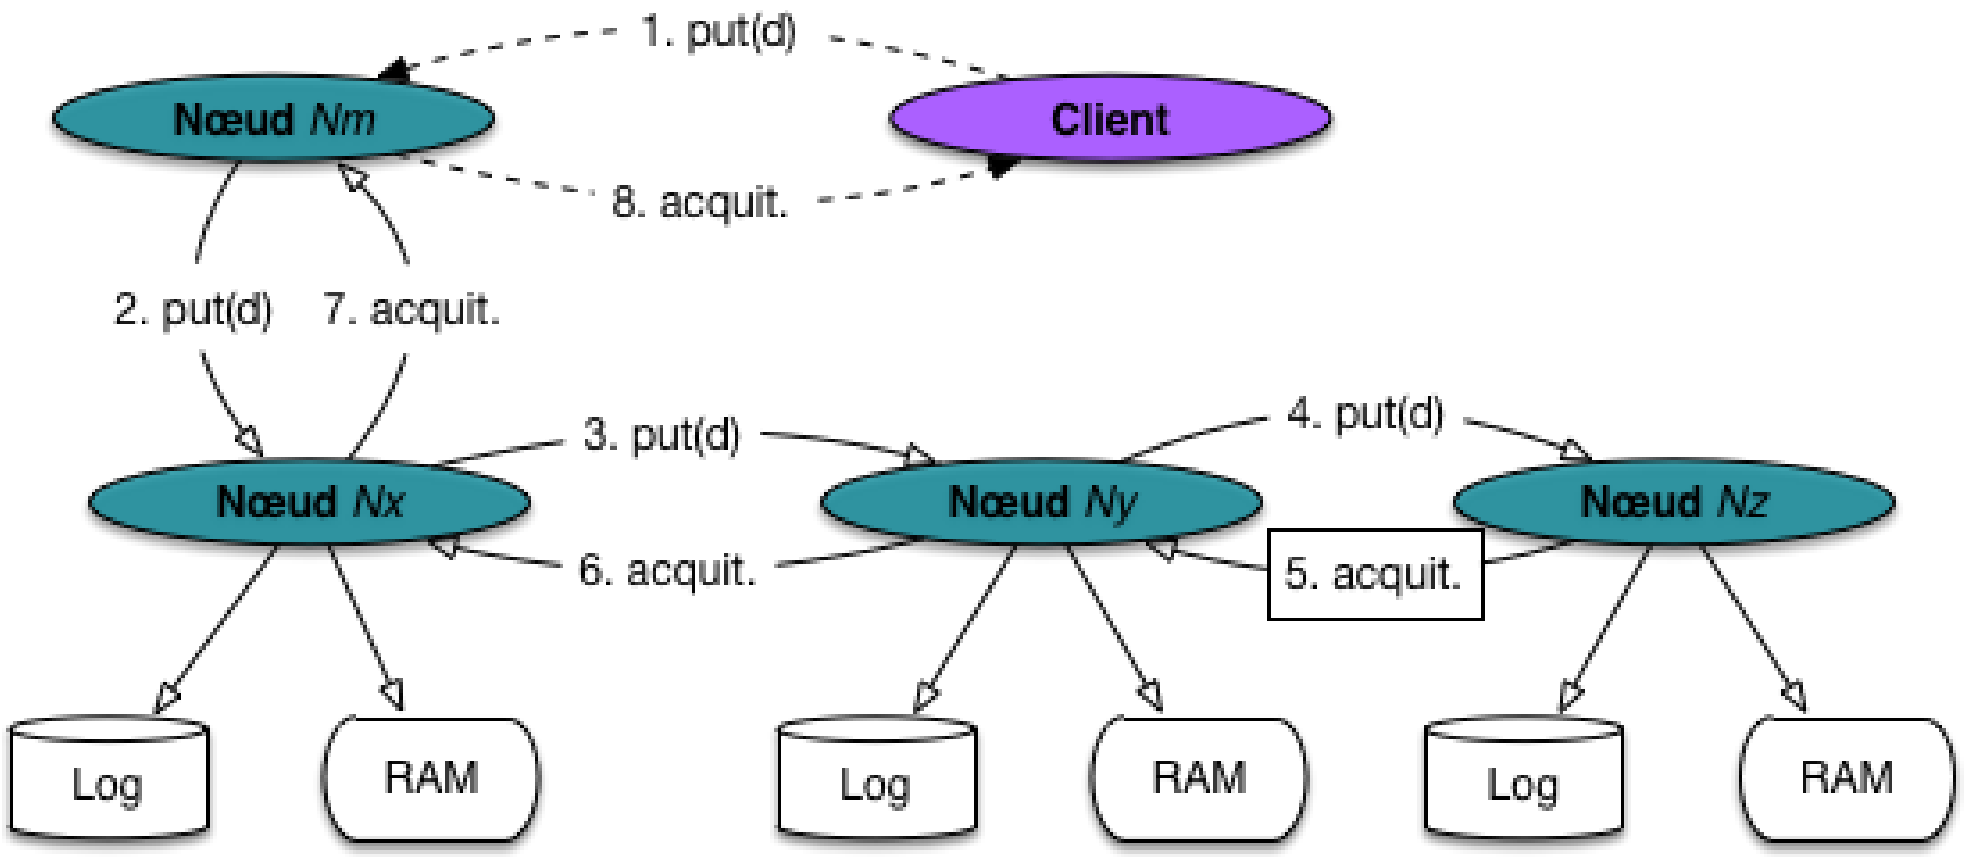

Réplication asynchrone

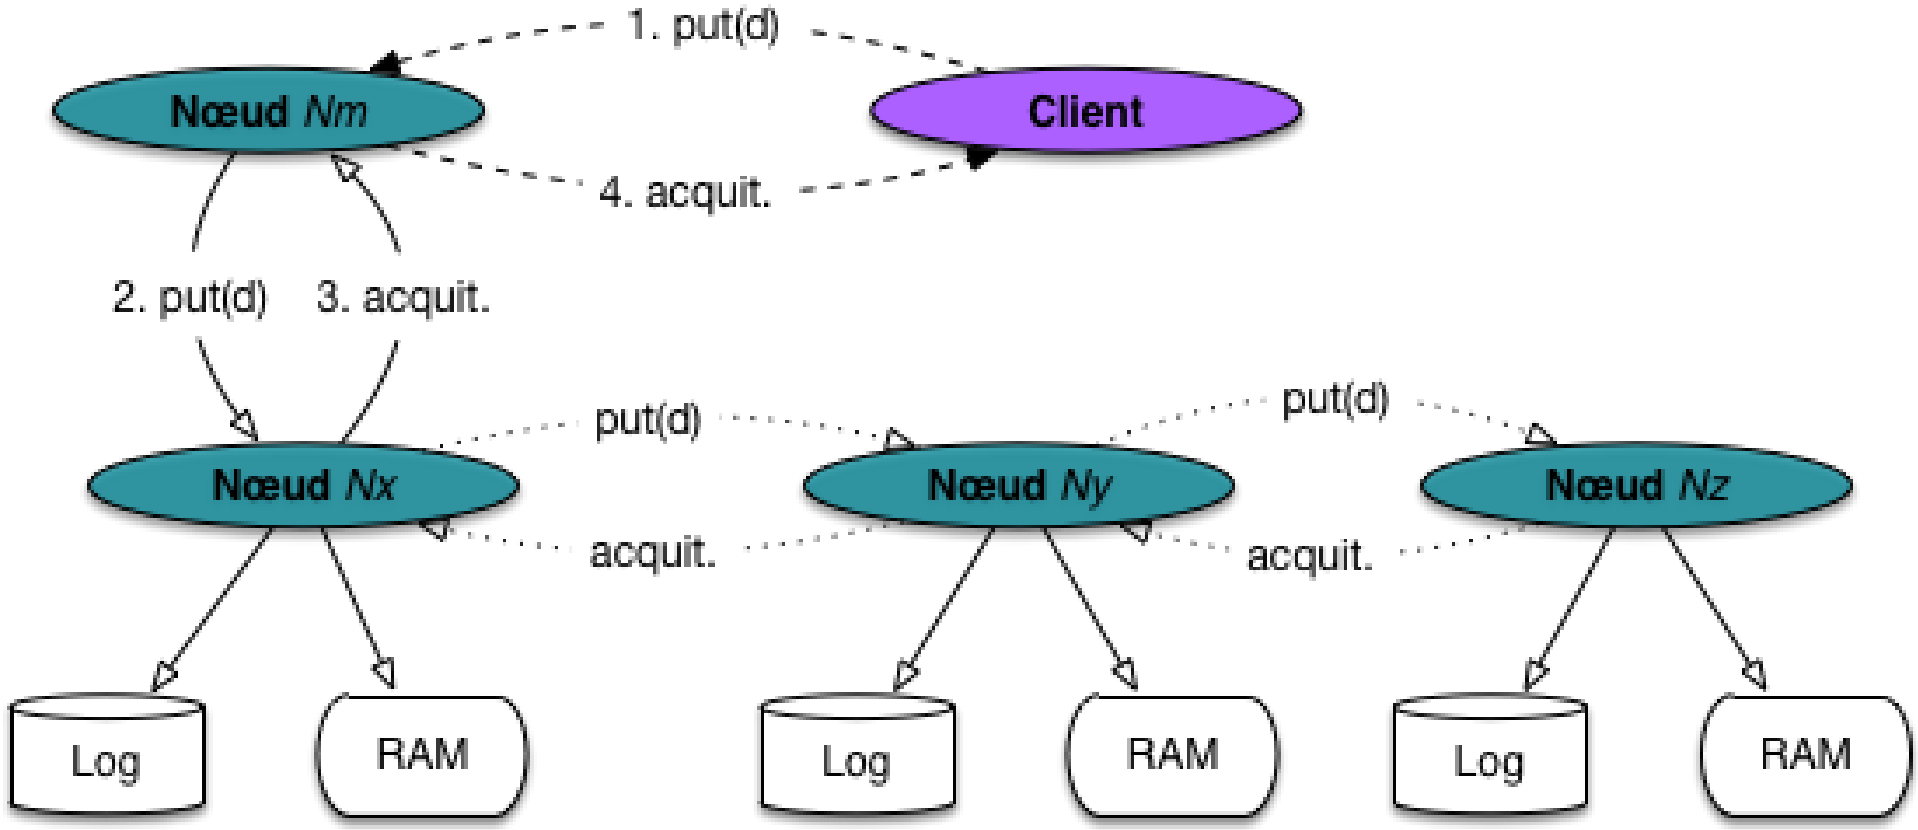

Réplication : une source d'incohérence

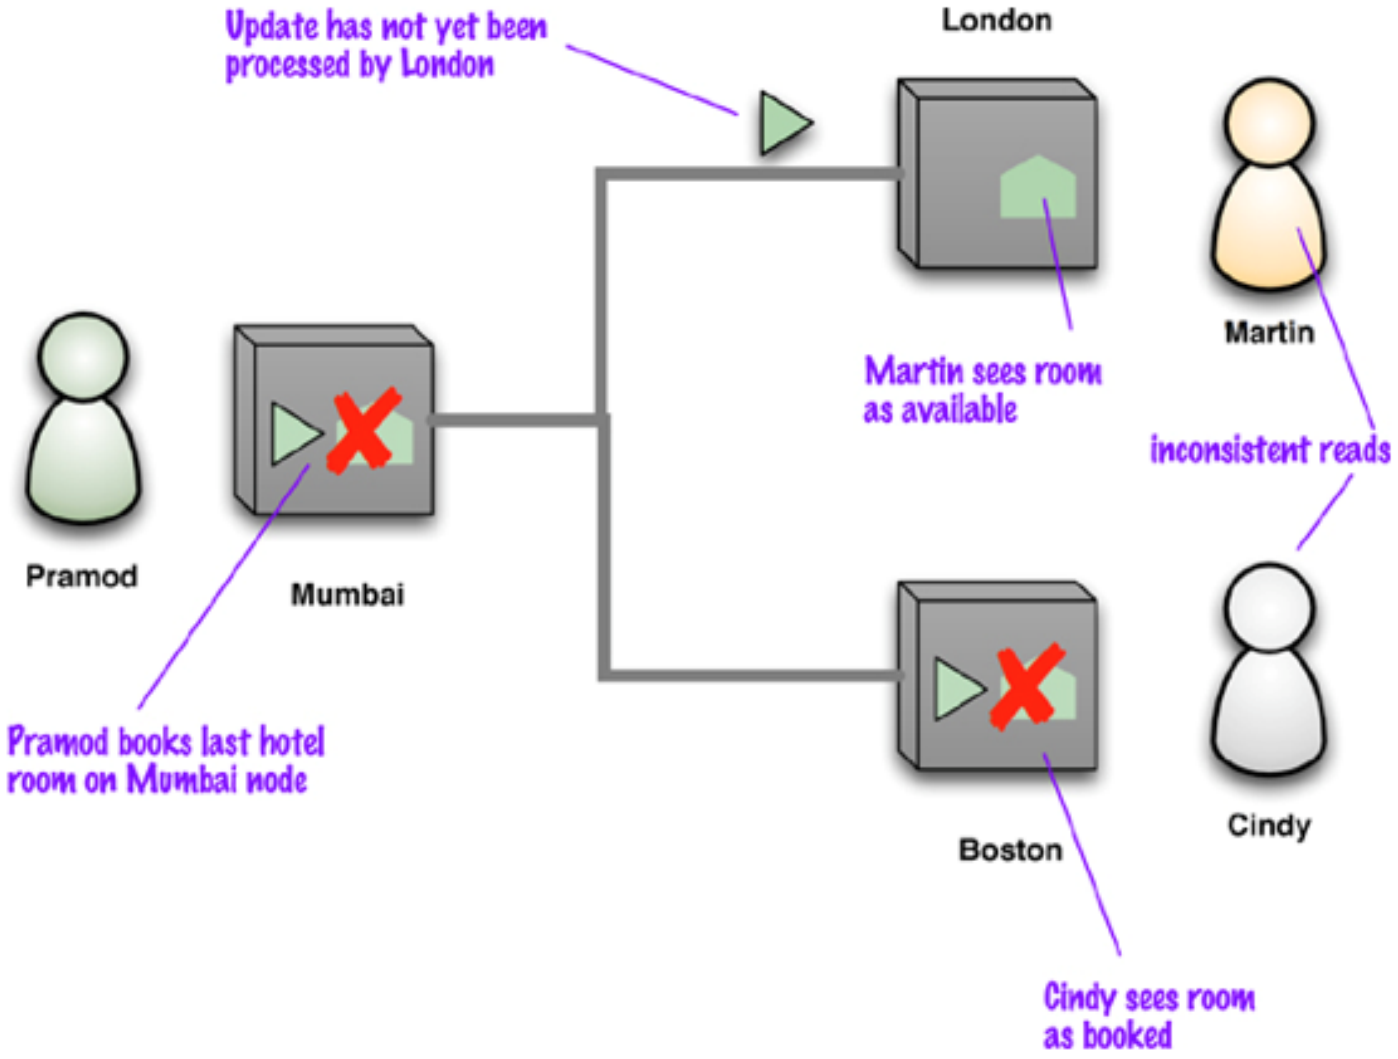

Figure 5.2. An example of replication inconsistency

Réplication et Cohérence

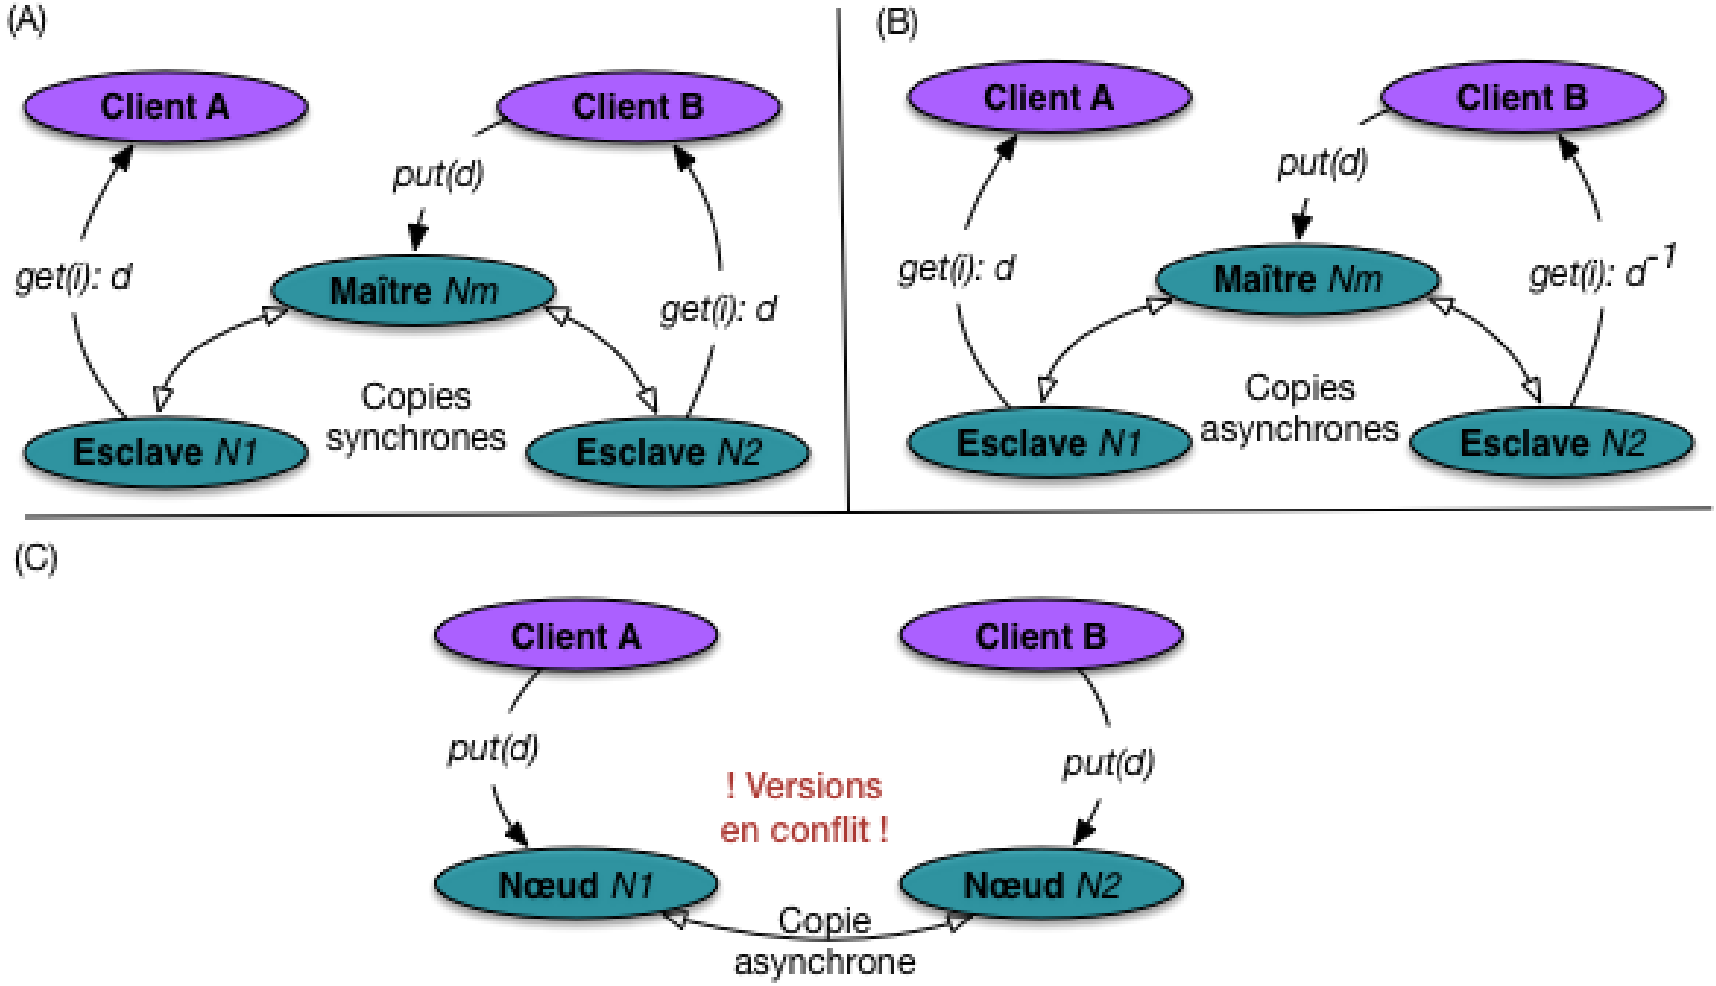

Cohérence

3 niveaux de cohérence :

- **Forte (propriétés ACID)** : toutes les copies sont toujours en phase, le prix à payer étant un délai pour chaque écriture;
- **Faible**: les copies ne sont pas forcément en phase, et rien ne garantit qu'elles le seront;
- **A terme (*Eventual consistency*) :** niveau de cohérence typique des systèmes NoSQL ; les copies ne sont pas immédiatement en phase, mais le système garantit qu'elles le seront « à terme »

Cohérence forte

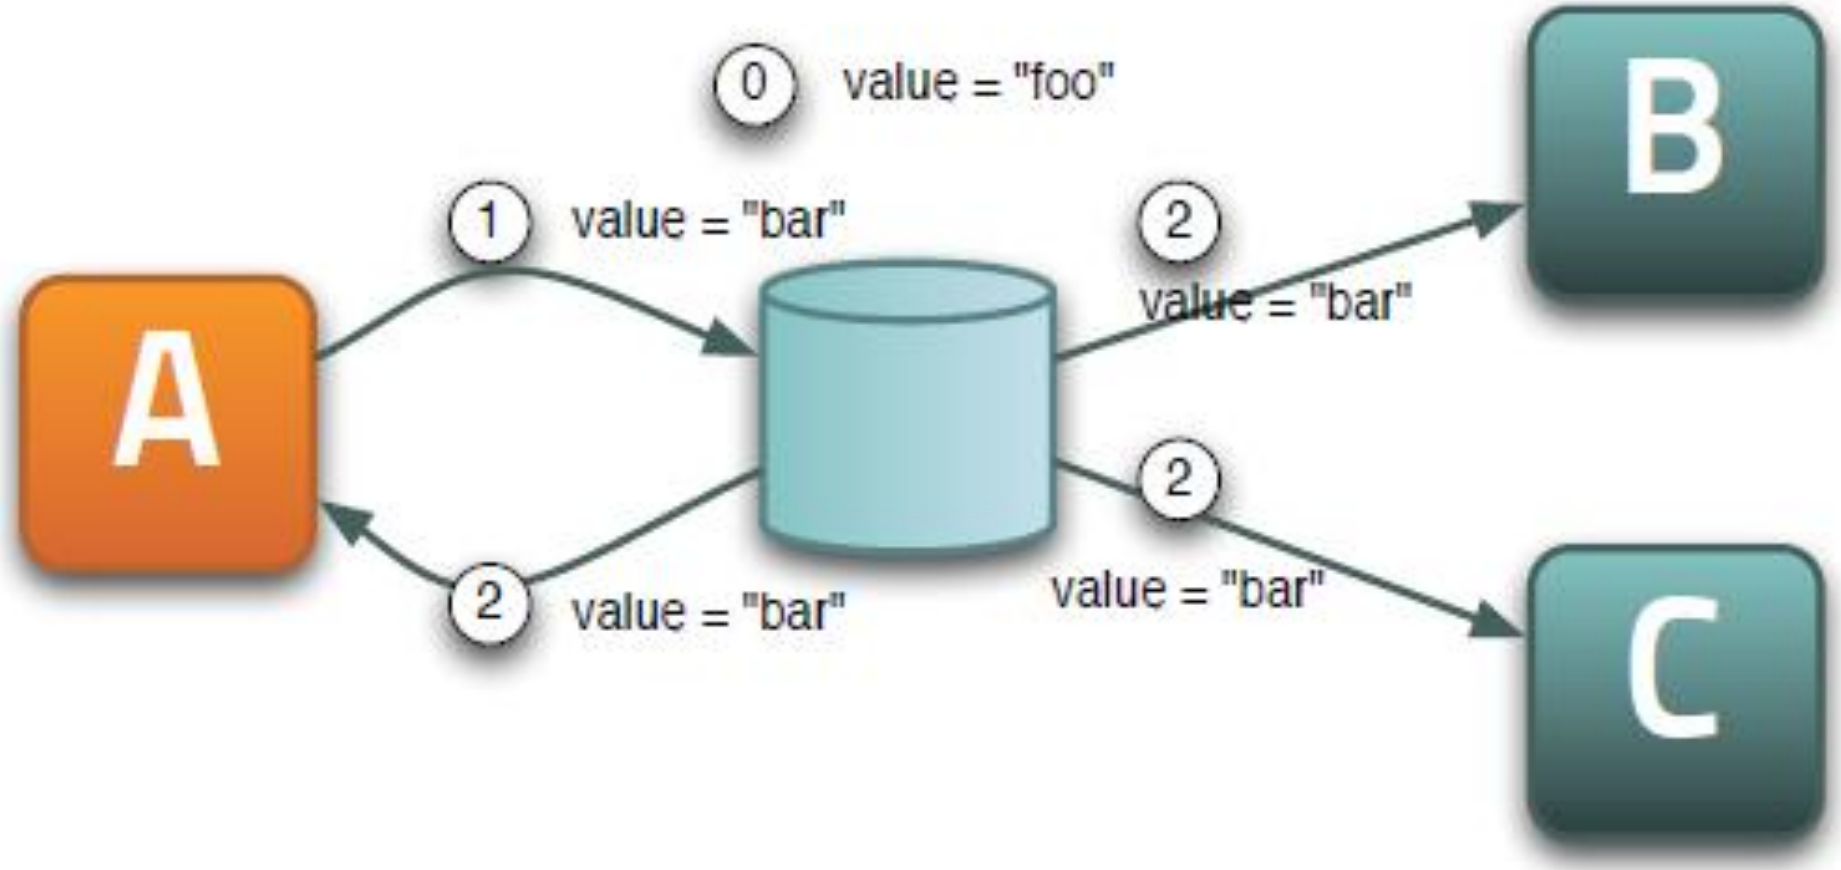

Après mise à jour : toute lecture renvoie la dernière mise à jour

Nombre d'écritures et de lectures minimales pour garantir la cohérence forte

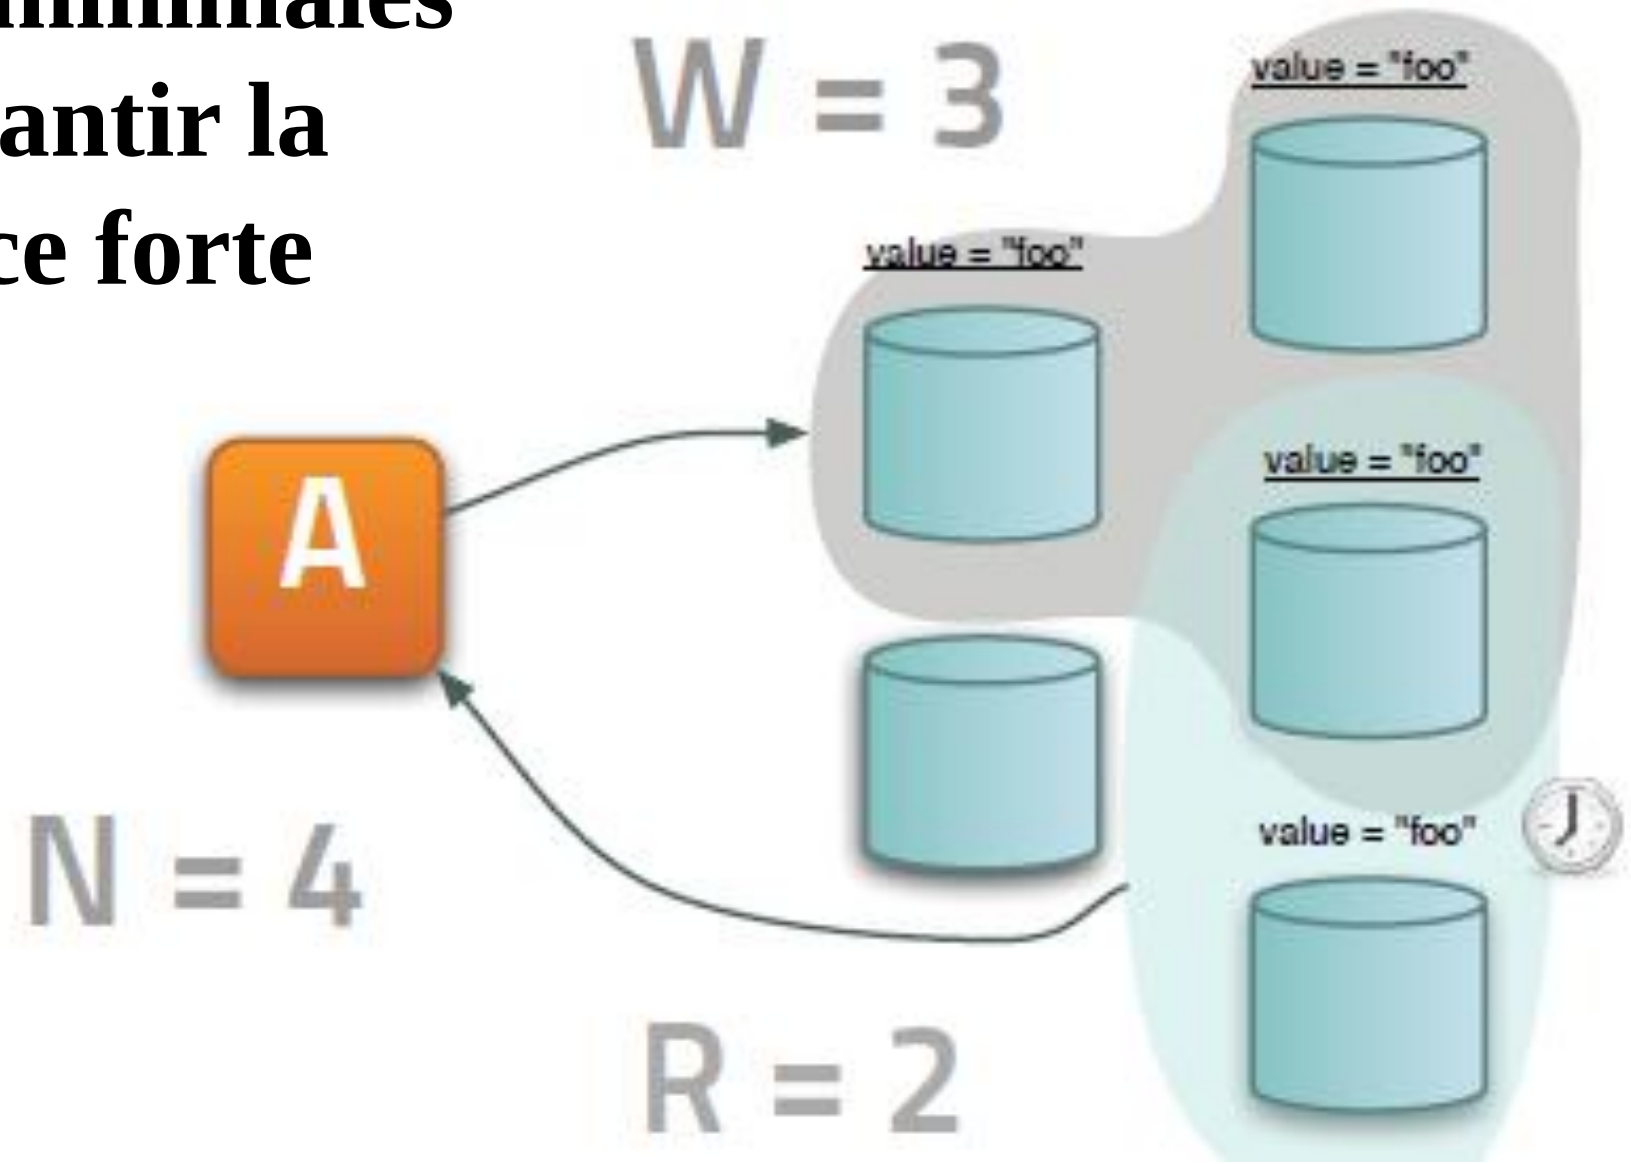

Cohérence faible

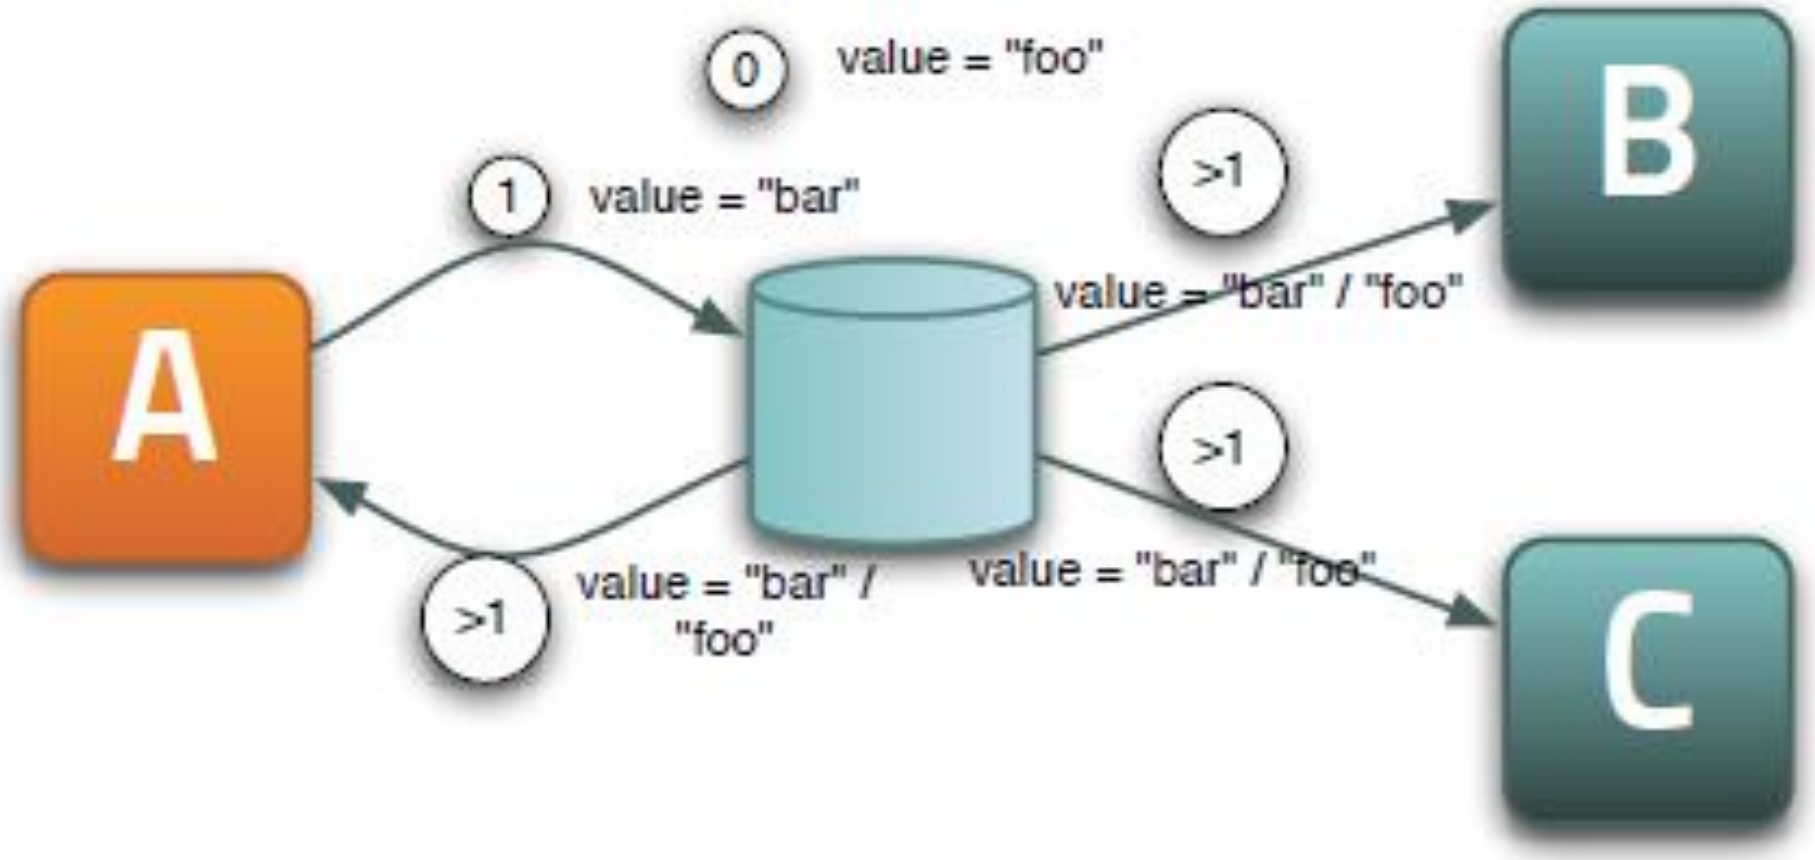

Après mise à jour : aucune garantie qu'une lecture renvoie la dernière mise à jour

Cohérence à termes (*Eventual Consistency*)

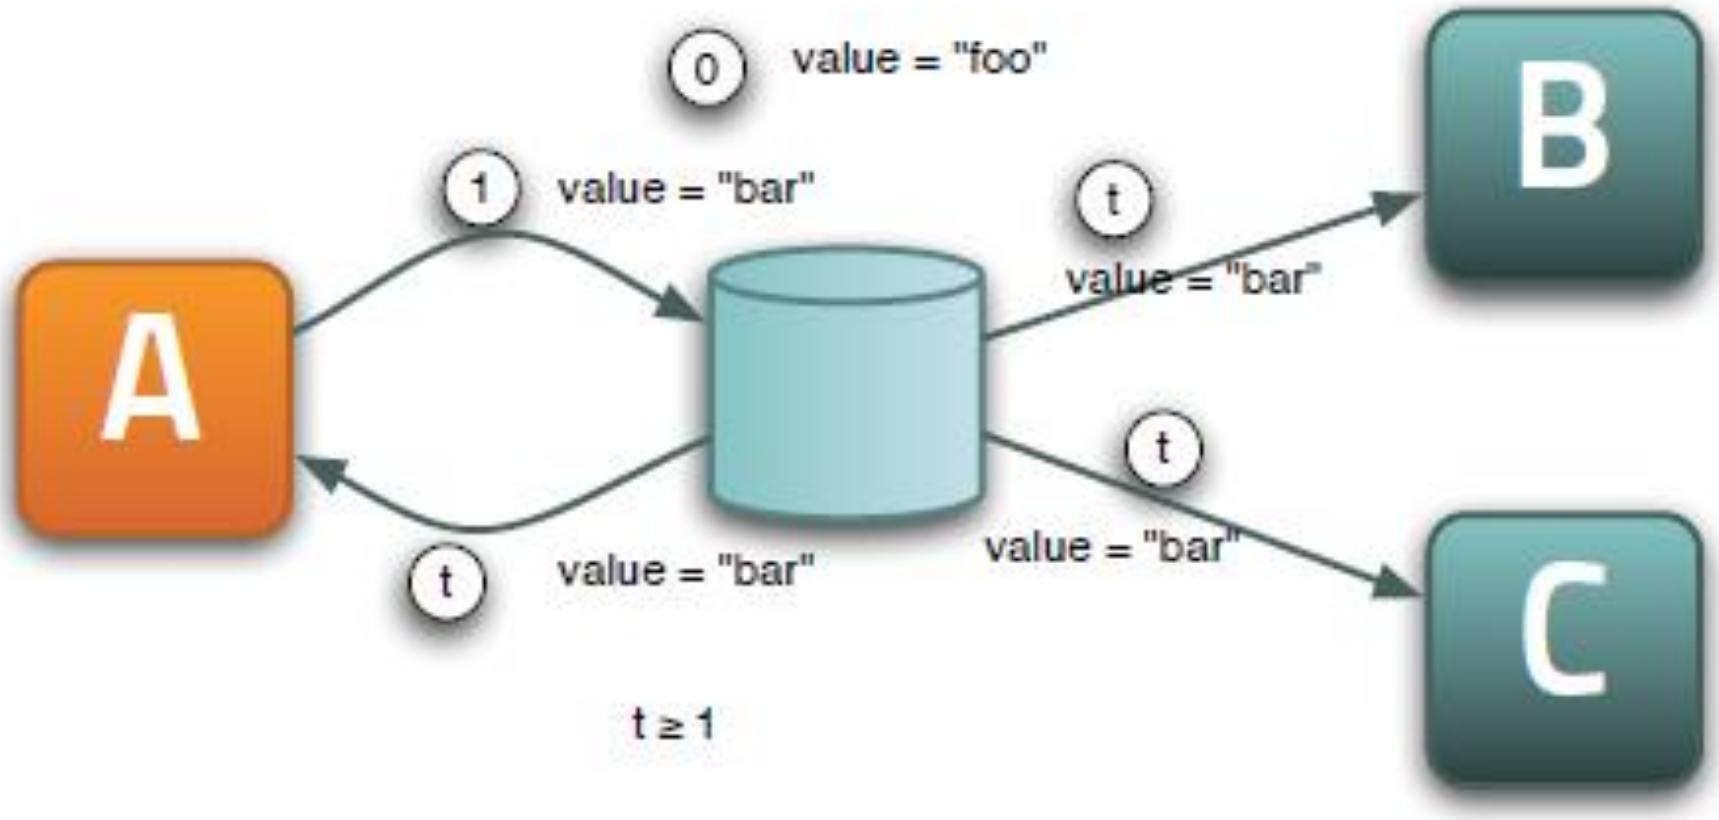

Cohérence à termes (*Eventual Consistency*) et réplication asynchrone

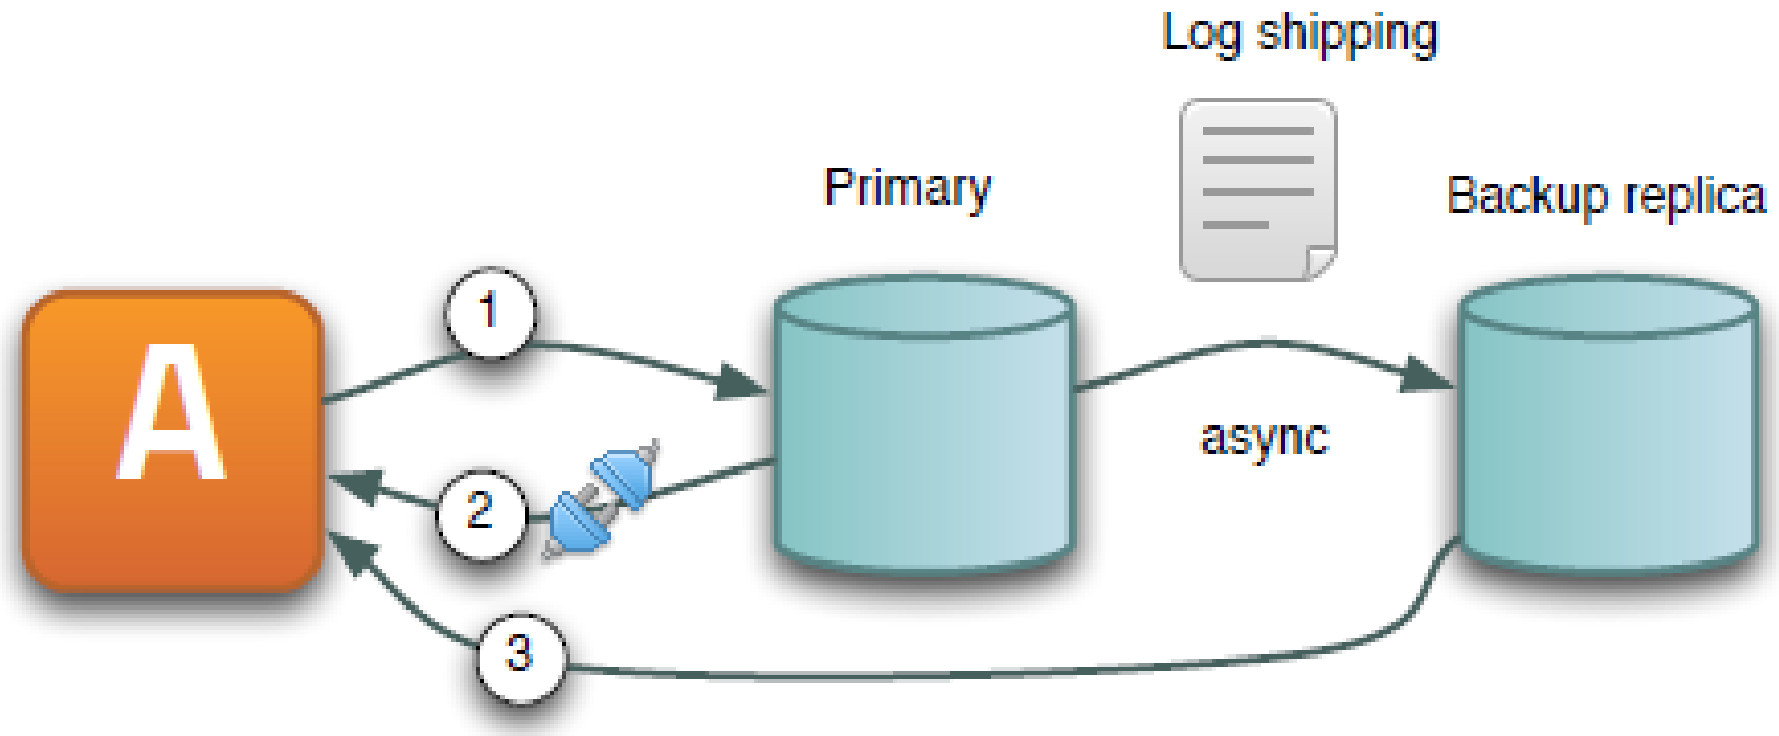

- Garantie de l'existence d'un instant fini (le plus proche possible) à partir duquel tous les réplicas seront synchronisés.
- Avant cet instant : fenêtre d'incohérence (il est possible que certains réplicas ne soient pas encore mis à jour).

©Maude Manouvrier - Univ. Paris-Dauphine – Reprise de https://www.slideshare.net/springerw/eventually-consistent

Réplication et reprise sur panne : communication entre le maître et ses esclaves

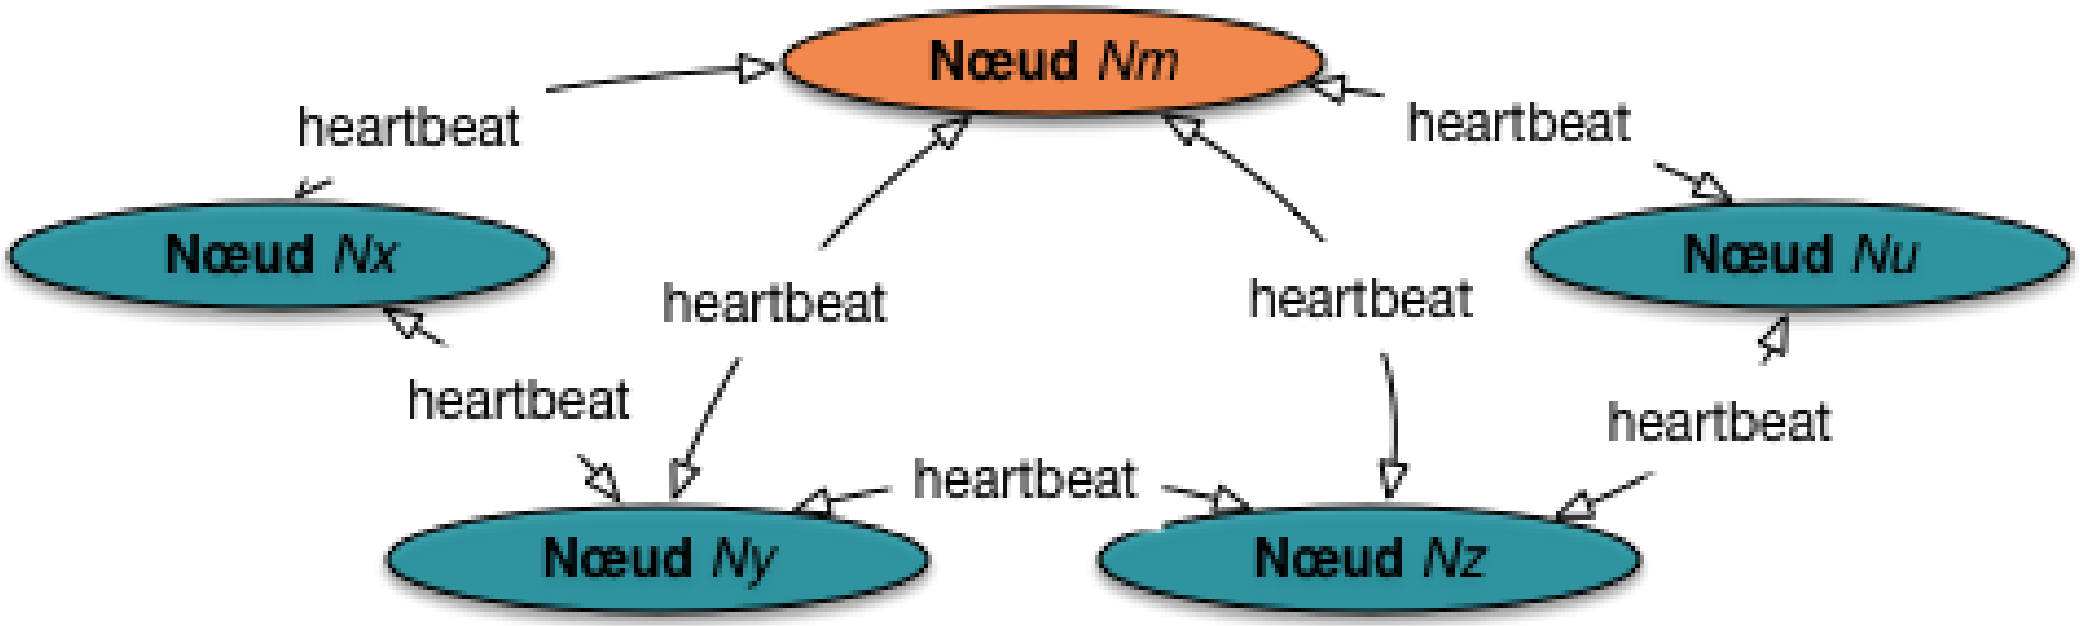

Réplication et reprise sur panne : élection d'un nouveau maître

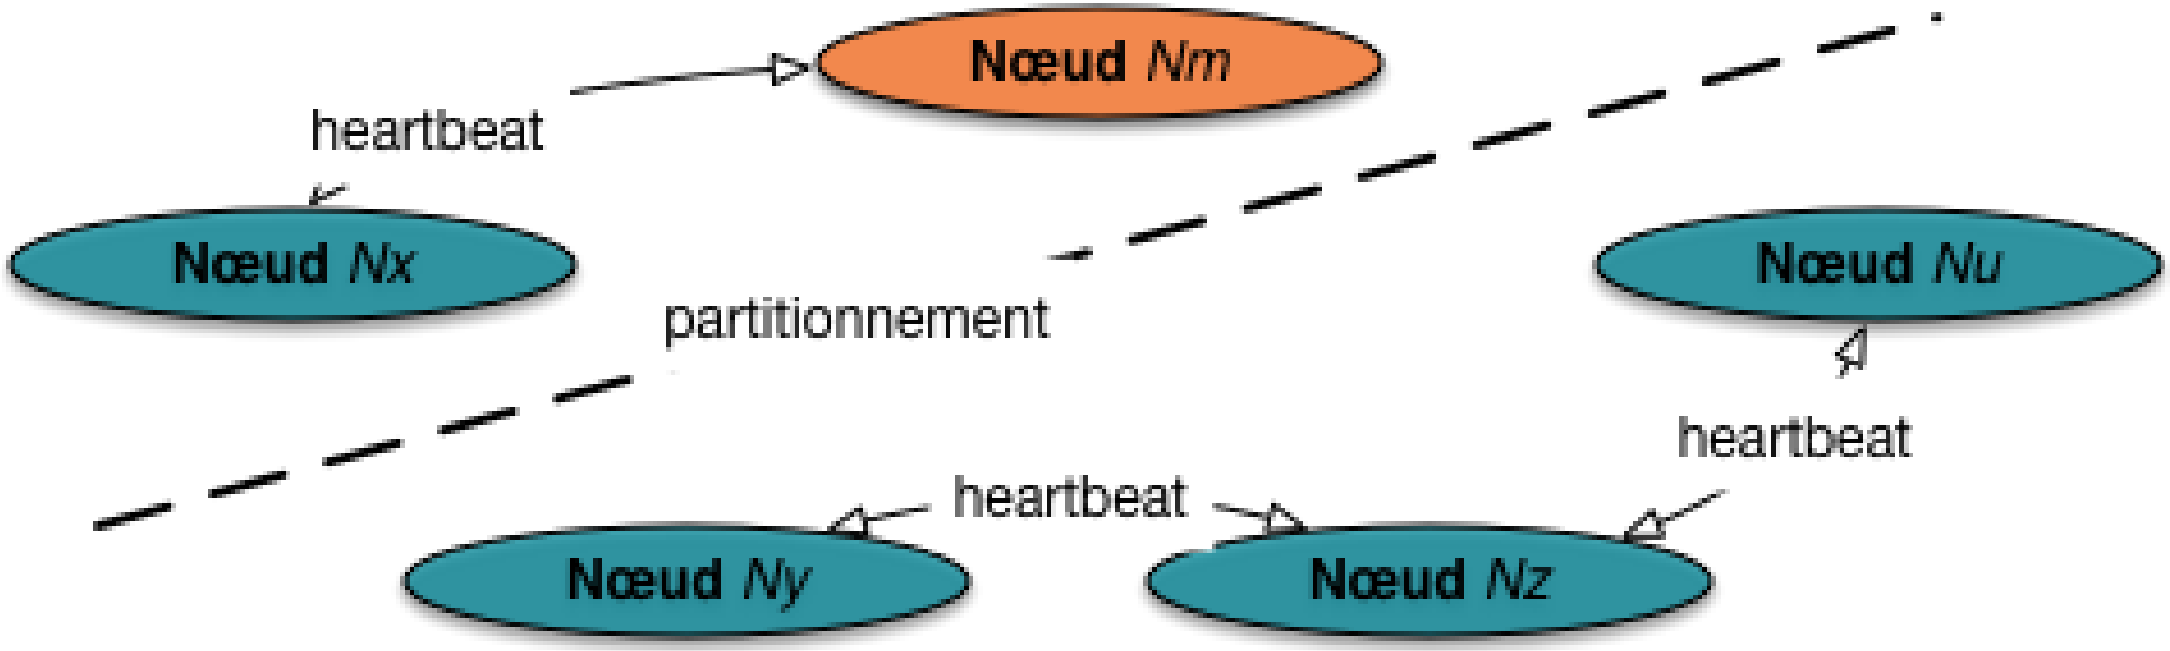

Acronyme ACID

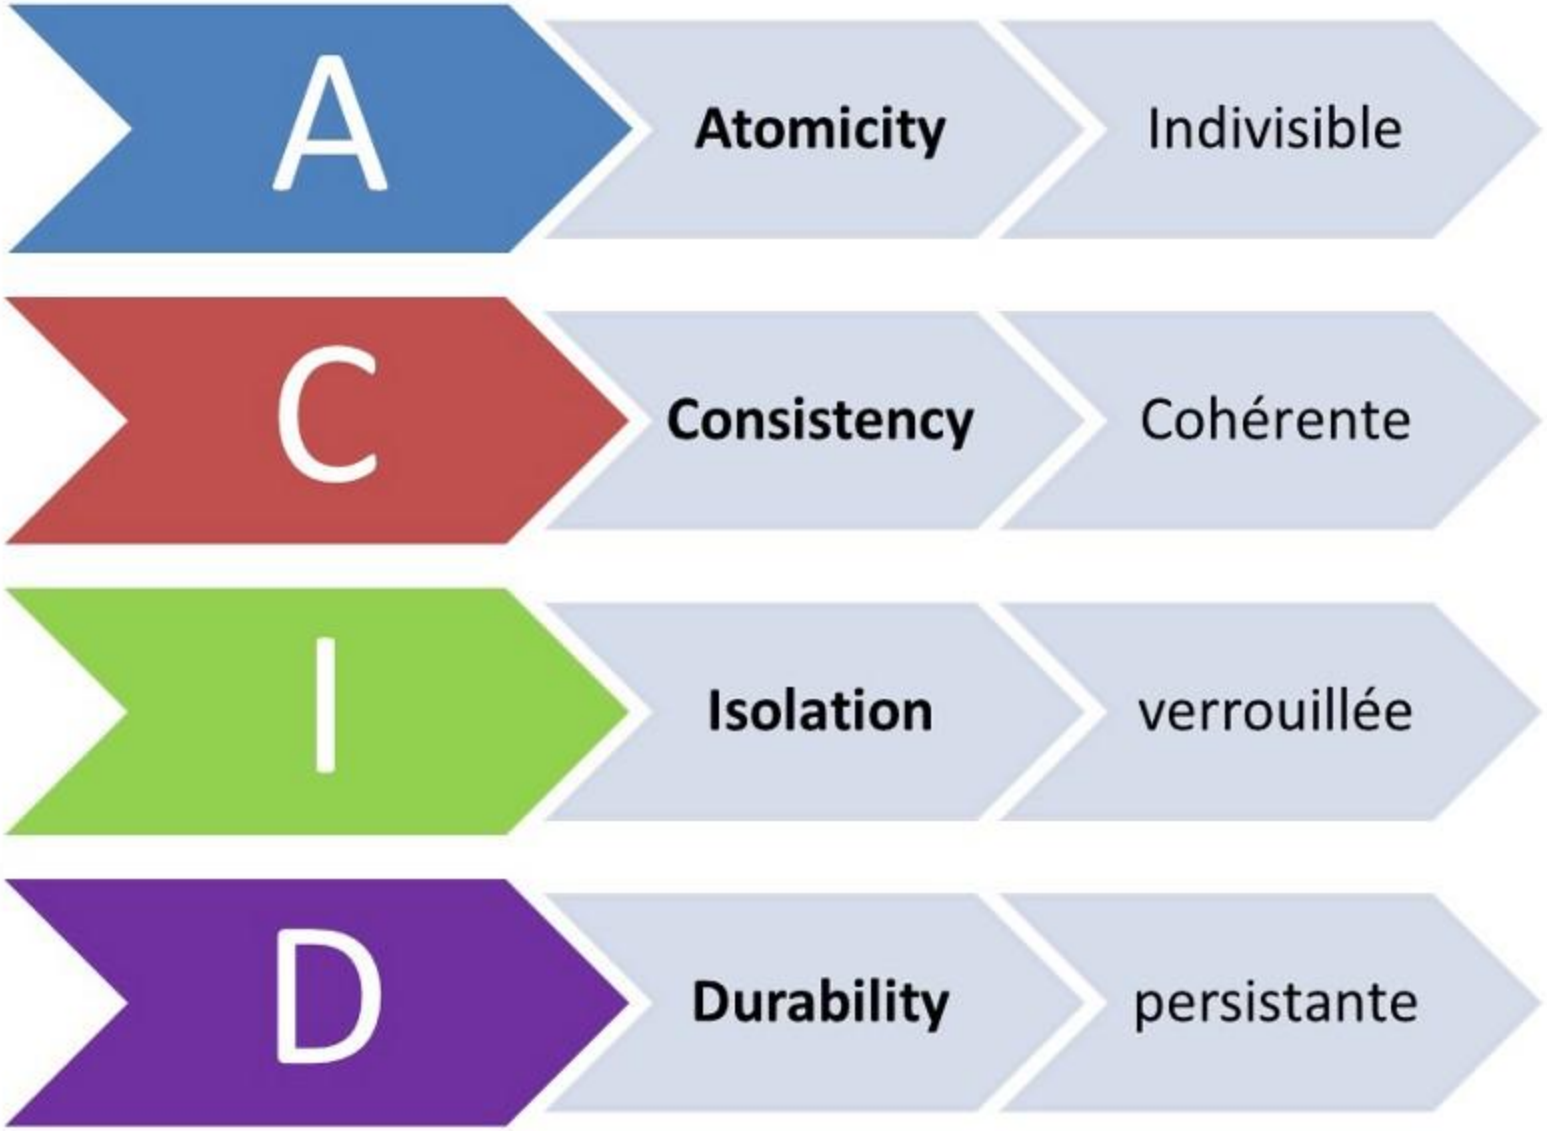

©Maude Manouvrier - Univ. Paris-Dauphine – Figure reprise de https://medium.com/opensanca/o-que-%C3%A9-acid-59b11a81e2c6

Définition des propriétés ACID

- **Atomicité :** Tout ou rien
  - Une transaction effectue toutes ses actions ou aucune
  - En cas d'annulation, les modifications engagées doivent être défaites
- **Cohérence** : Intégrité des données

  Passage d'un état cohérent de la base à un autre état cohérent de la base de données
- **Isolation** : Pas d'interférence entre transactions

  Les résultats d'une transaction ne sont visibles par les autres transactions qu'après sa validation
- **Durabilité** : Journalisation des mises à jour

  Les modifications effectuées sont garanties même en cas de panne

©Maude Manouvrier - Univ. Paris-Dauphine

Atomicité et Cohérence

Before: X : 500	Y: 200
Transaction T	
T1	**T2**
Read (X) X: = X – 100 Write (X)	Read (Y) Y: = Y + 100 Write (Y)
After: X : 400	Y : 300

- Exécution complète de T1 et T2 => cohérence
- Panne après l'exécution de *write(X)* mais avant celle de *write(Y)* => incohérence

Isolation et Cohérence

T	T''
(1) Read (X)	(4) Read (X)
(2) X: = X*100	(5) Read (Y)
(3) Write (X)	(6) Z: = X + Y
(7) Read (Y)	(9) Write (Z)
(8) Y: = Y – 50	
(10) Write (Y)	

- Exécution complète de T suivie de celle de T'' => isolation et cohérence
- Entrelacement des op. de T'' et de T =>
  - T'' lit une valeur impropre de X (en cas d'annulation de T il faut annuler T'')
  - Etat incohérent de la base (≠ de celui obtenu si on avait tout T puis tout T'')

Ordonnancement sérialisable

T_1: Solde A - x; Solde B + x;

T_2 : Solde A - y; Solde B + y;

T_3 : Solde A - z; Solde B + z;

Exécution séquentielle : T_1 T_2 T_3

Une exécution sérialisable équivalente à T_1 T_2 T_3 :

Solde A - x;

Solde A - y;

Solde B + x;

Solde A - z;

Solde B + y;

Solde B + z;

L'item A voit passer les transaction dans l'ordre
T1 T2 T3

L'item B voit passer les transaction dans l'ordre
T1 T2 T3

©Maude Manouvrier - Univ. Paris-Dauphine

Durabilité

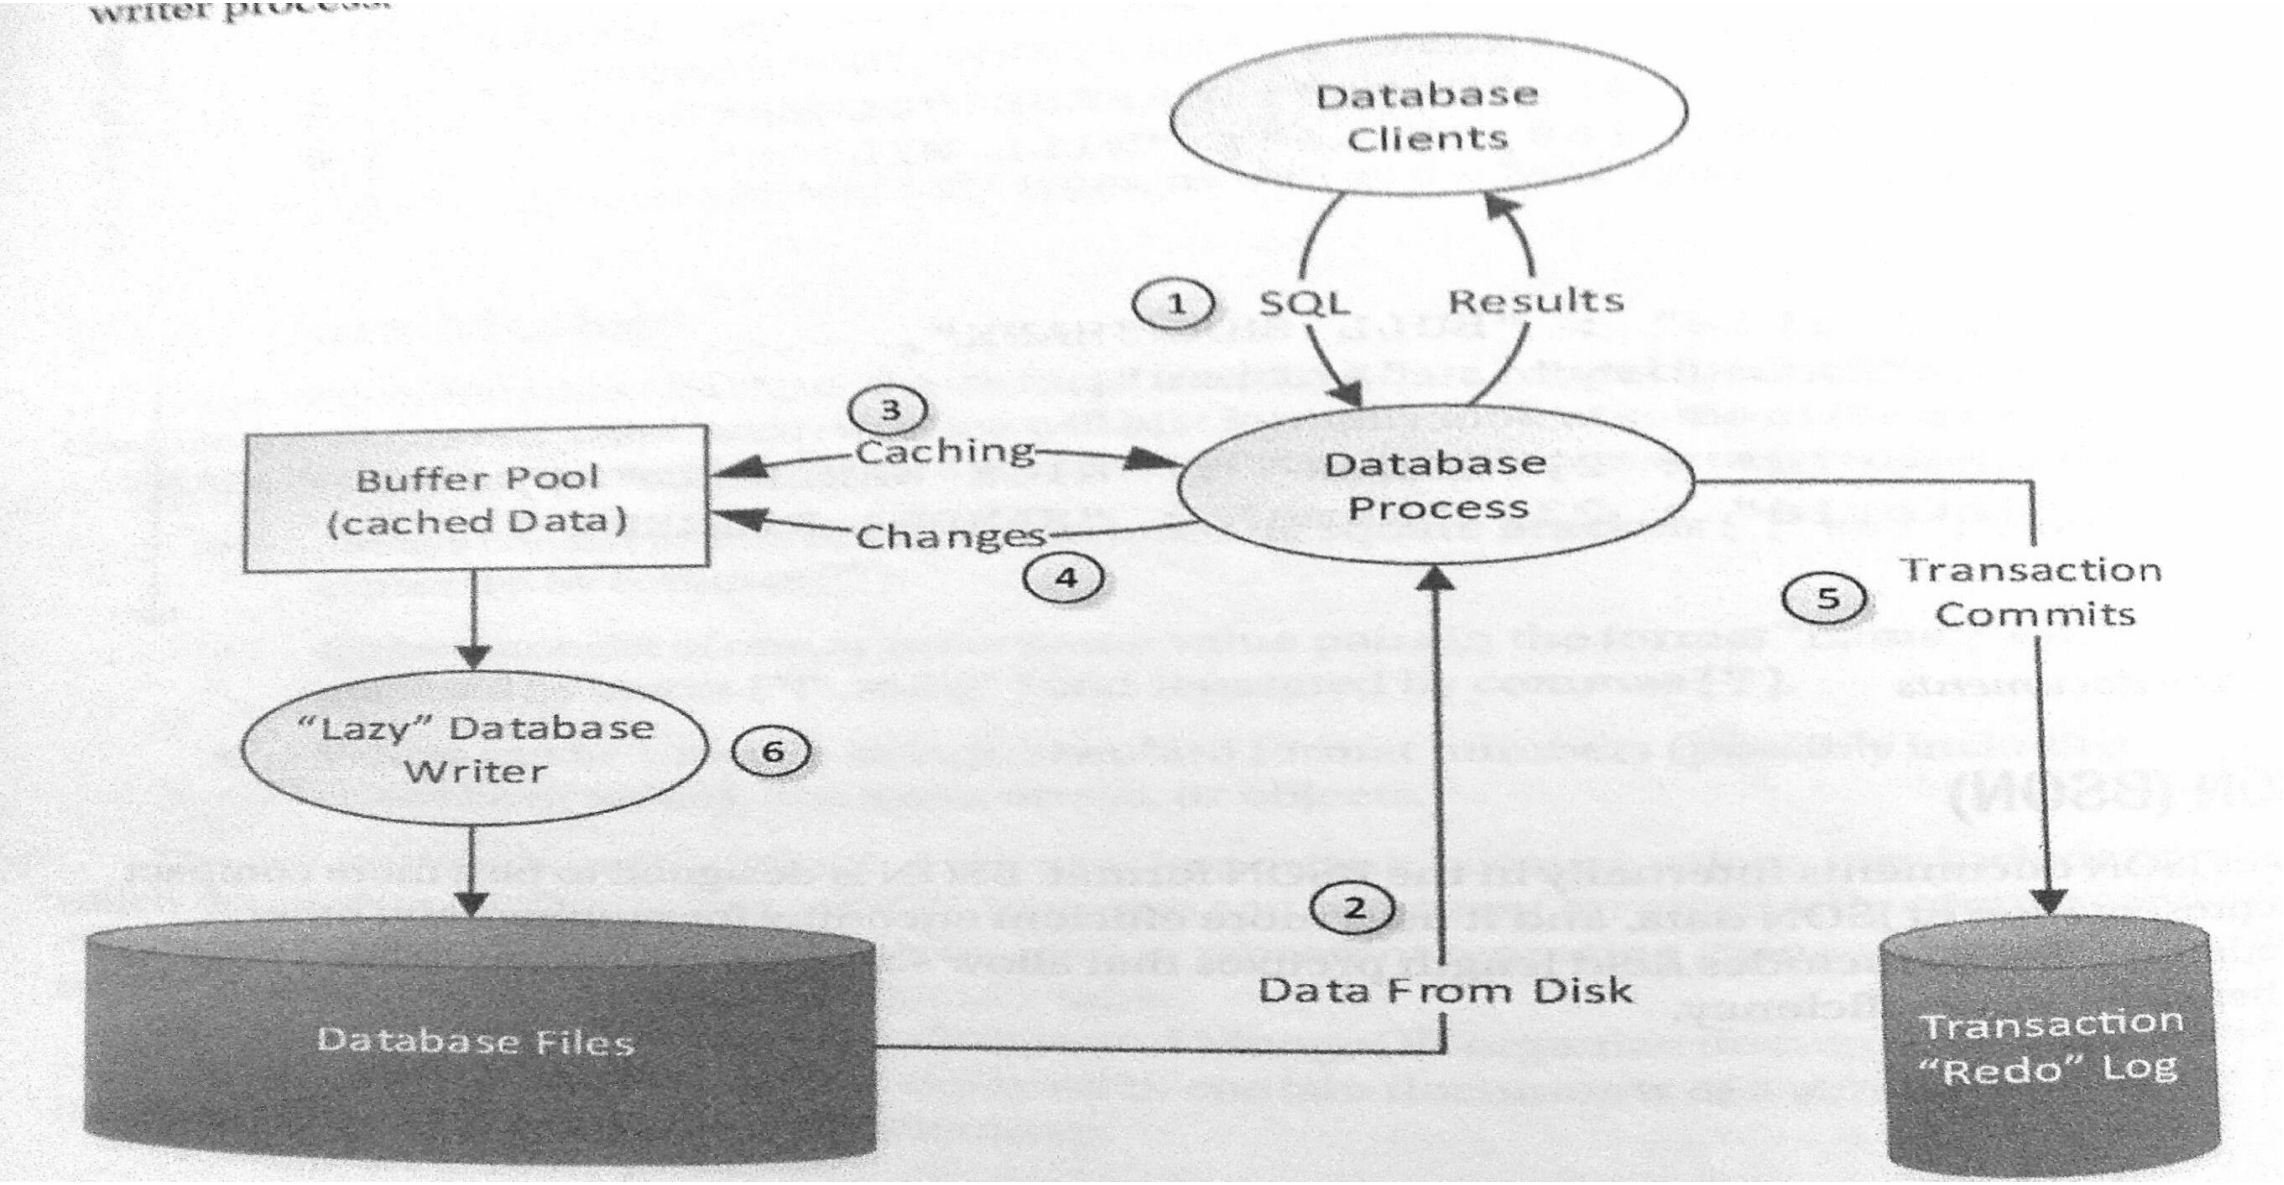
Database Clients
1
SQL
Results
3
Caching
Buffer Pool (cached Data)
Changes
4
Database Process
5
Transaction Commits
"Lazy" Database Writer
6
2
Data From Disk
Database Files
Transaction "Redo" Log

Conflits

- **Ecriture - Lecture :**
  - **Lecture impropre ou parasite (*dirty read*)**
  - **Placement momentanée de la base dans un état incohérent**
  - **Annulation en cascade de transactions**
- **Lecture - Ecriture :**
  - **Lecture non reproductible (*unrepeatable read*)**
  - **Incohérence**
- **Ecriture- Ecriture :**

  Perte de mises à jour (*blind write*)

©Maude Manouvrier - Univ. Paris-Dauphine

Conflits : perte de mise à jour

- T1 et T2 transactions concurrentes
- T1 : lire (x) ; x <- x + 10 ; écrire (x)
- T2 : lire (x) ; x <- x + 20; écrire (x)
- Au départ x = 50

T1	T2
Lire (x) (T1 lit x = 50 dans BD)	
x <- x + 10	
	Lire (x) (T1 lit x = 50 dans BD)
Ecrire x (dans BD : x = 60)	
	x <- x + 20
	Ecrire x (dans BD : x = 70)

temps

Conflits : lecture impropre (1/3)

- T1 et T2 transactions concurrentes

T1	T2
UPDATE comptes SET solde = 25000 WHERE num_compte = '9' ;	
	SELECT solde FROM comptes WHERE num_compte = '9' ;
ROLLBACK	

temps

Conflits : lecture impropre (2/3)

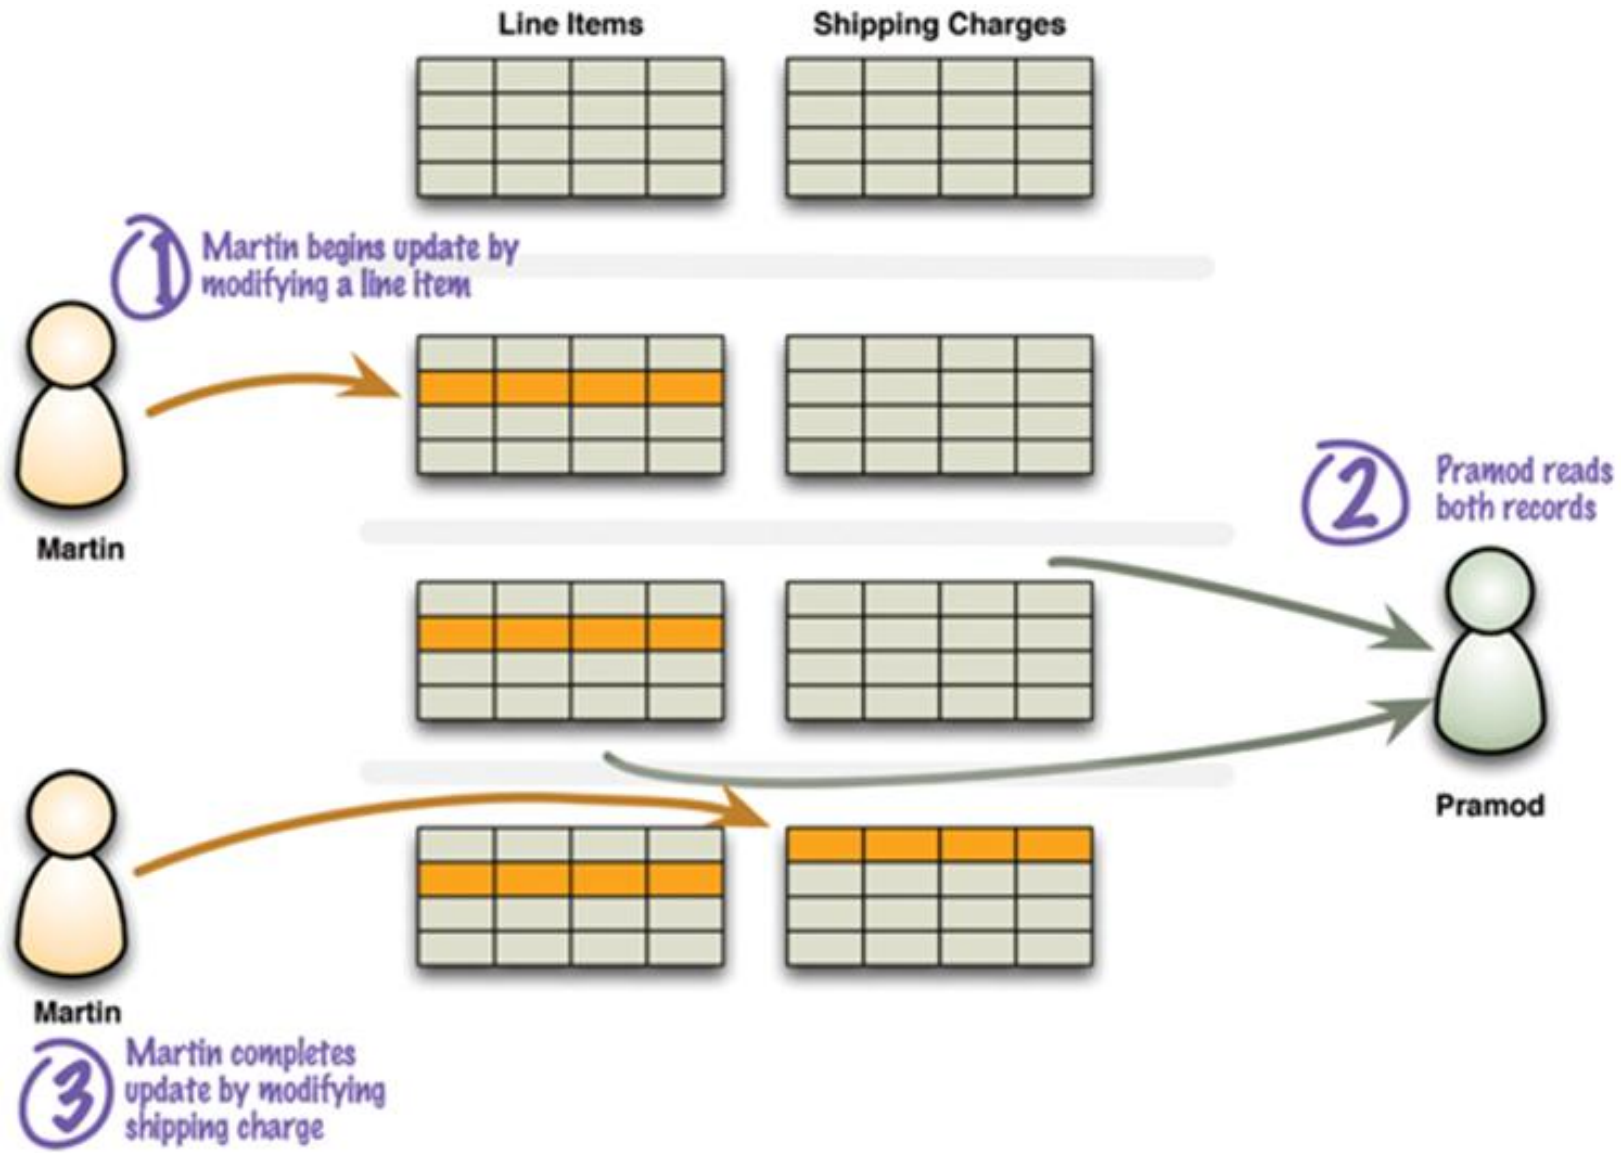

Conflits : exemple de lecture impropre (3/3)

- T1 et T2 transactions concurrentes
- T1 transfère 10 euros du compte '9' vers le compte '5'
- T2 affiche le solde total des 2 comptes

T1	T2
UPDATE Comptes SET solde = solde - 10 WHERE num_compte = '9' ;	
	SELECT SUM (solde) FROM Comptes WHERE num_compte in ('9', '5') ;
UPDATE Comptes SET solde = solde + 10 WHERE num_compte = '5' ;	
COMMIT	

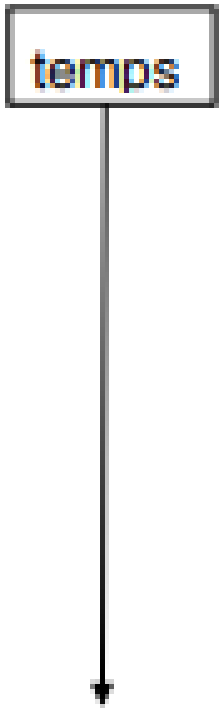

Conflits : lecture non reproductible

- T1 et T2 transactions concurrentes
- T1 effectue plusieurs fois la lecture du même objet

temps

T1	T2
SELECT points FROM Resultats WHERE num_cours = 5 AND num_eleve = 7 ;	
	UPDATE Resultats SET points = points * 1.1 WHERE num_cours = 5 AND nom_eleve = 7 ;
SELECT points FROM Resultats WHERE num_cours = 5 AND num_eleve = 7 ;	
COMMIT	

Conflits : lecture fantôme

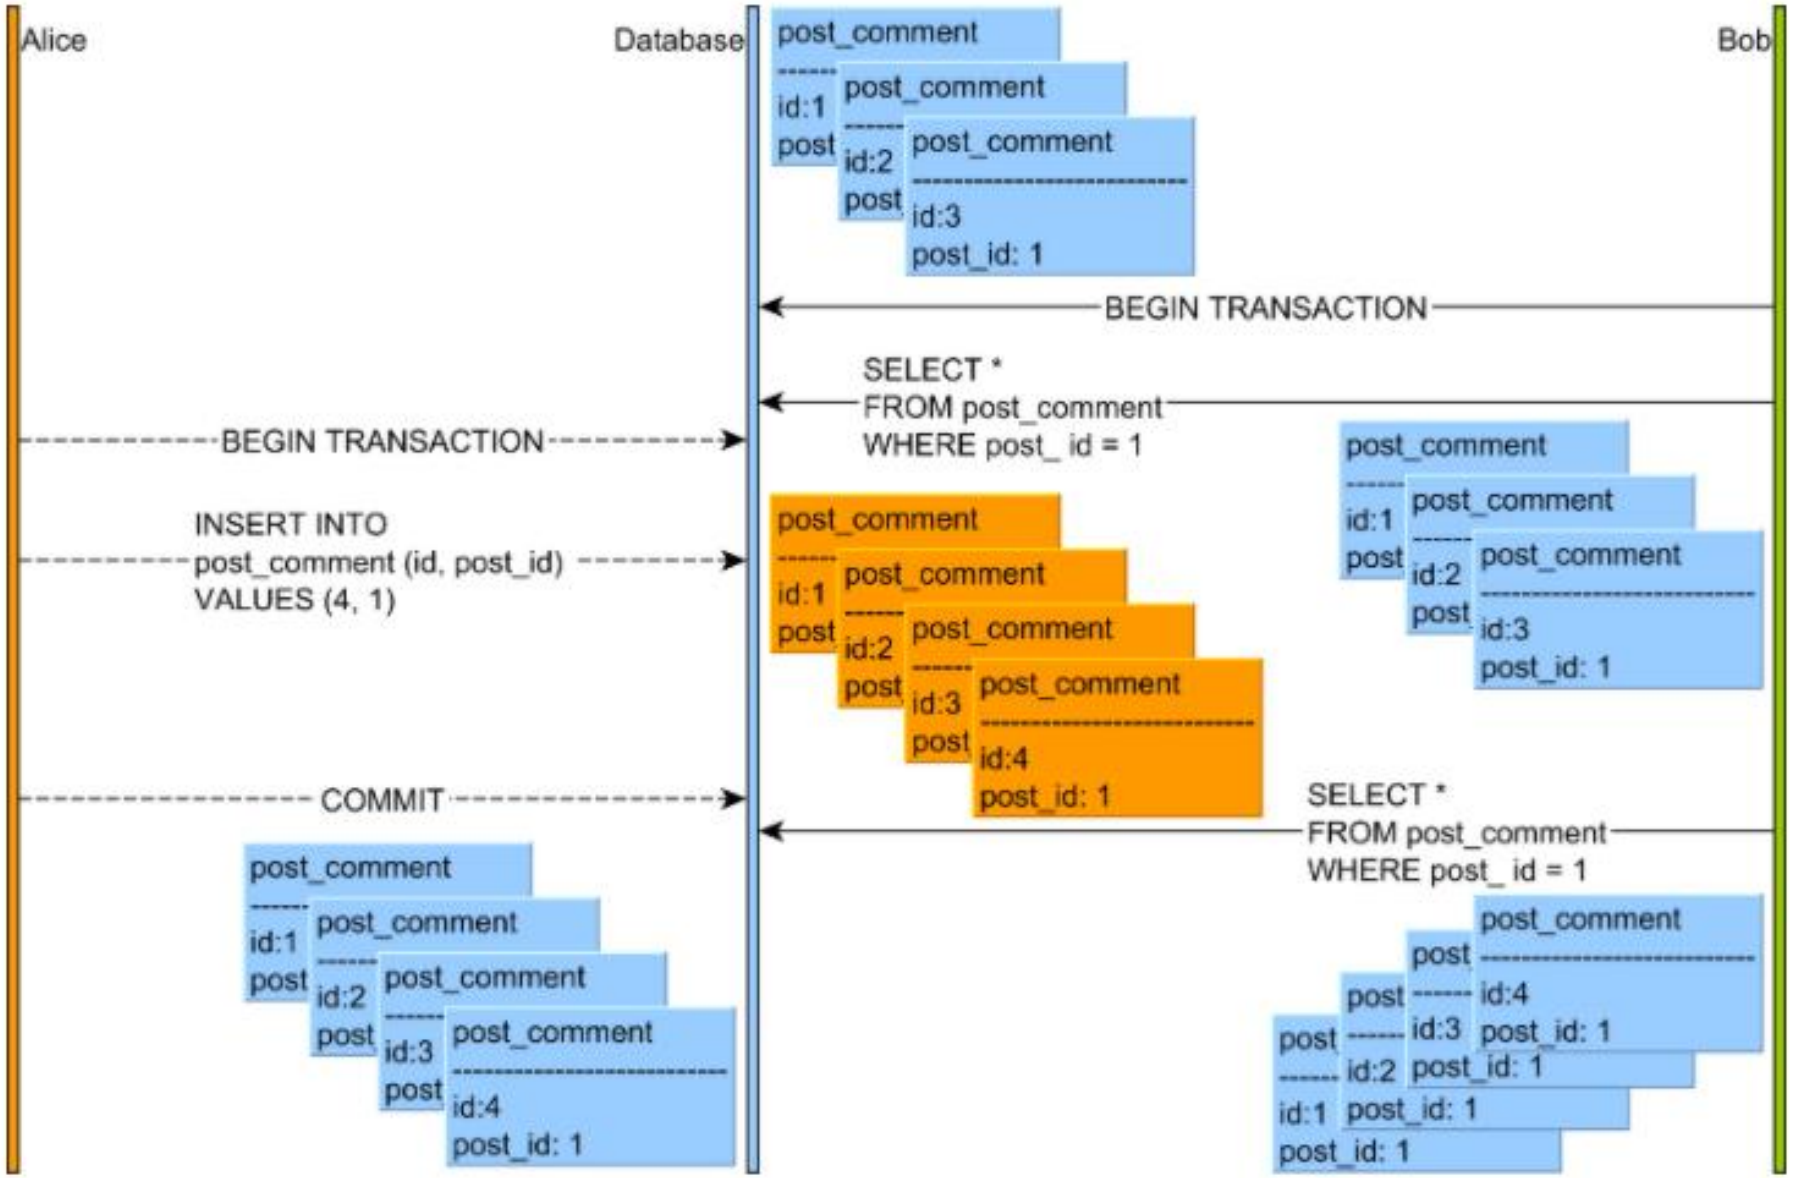

Anomalies d’isolation

3 types d'anomalies d'isolation défini dans ANSI SQL92 :

- **Lectures sales ou impropres**

  Une transaction T1 lit des modifications non validées d’items effectuées par T2.

  En cas de annulation de T2, T1 a lu des valeurs invalides

- **Lectures non reproductibles**

  T1 lit un item, T2 modifie ce même item, T1 relit ce item et obtient une valeur différente

- **Lectures fantômes**

  T1 lit un ensemble de nuplets, T2 ajoute/supprime des nuplets, T1 relit l’ensemble de nuplets et obtient un ensemble différent comme résultat

©Maude Manouvrier - Univ. Paris-Dauphine

Degrés d'isolation en SQL

Degré	Lecture impropre	Lecture non reproductible	Références fantômes
READ UNCOMMITTED	OUI	OUI	OUI
READ COMMITTED	NON	OUI	OUI
REPEATABLE READ	NON	NON	OUI
SERIALIZABLE	NON	NON	NON

```
SET TRANSACTION ISOLATION LEVEL { READ UNCOMMITTED | READ COMMITTED |
REPEATABLE READ | SERIALIZABLE }
```

©Maude Manouvrier - Univ. Paris-Dauphine

Degrés d’isolation et conflits

- **Degré 0**

  Résolution des pertes de mises à jour

- **Degré 1**

  Pas d’annulation en cascade + Degré 0

- **Degré 2**

  Pas de lecture impropre + Degré 1

- **Degré 3**

  Isolation totale - Mise en attente des transactions en conflit

©Maude Manouvrier - Univ. Paris-Dauphine

Gestion des conflits

- **Approche pessimiste** : prévention des conflits par ex. en utilisant le verrouillage
- **Approche optimiste** : détection des conflits

Verrouillage Pessimiste

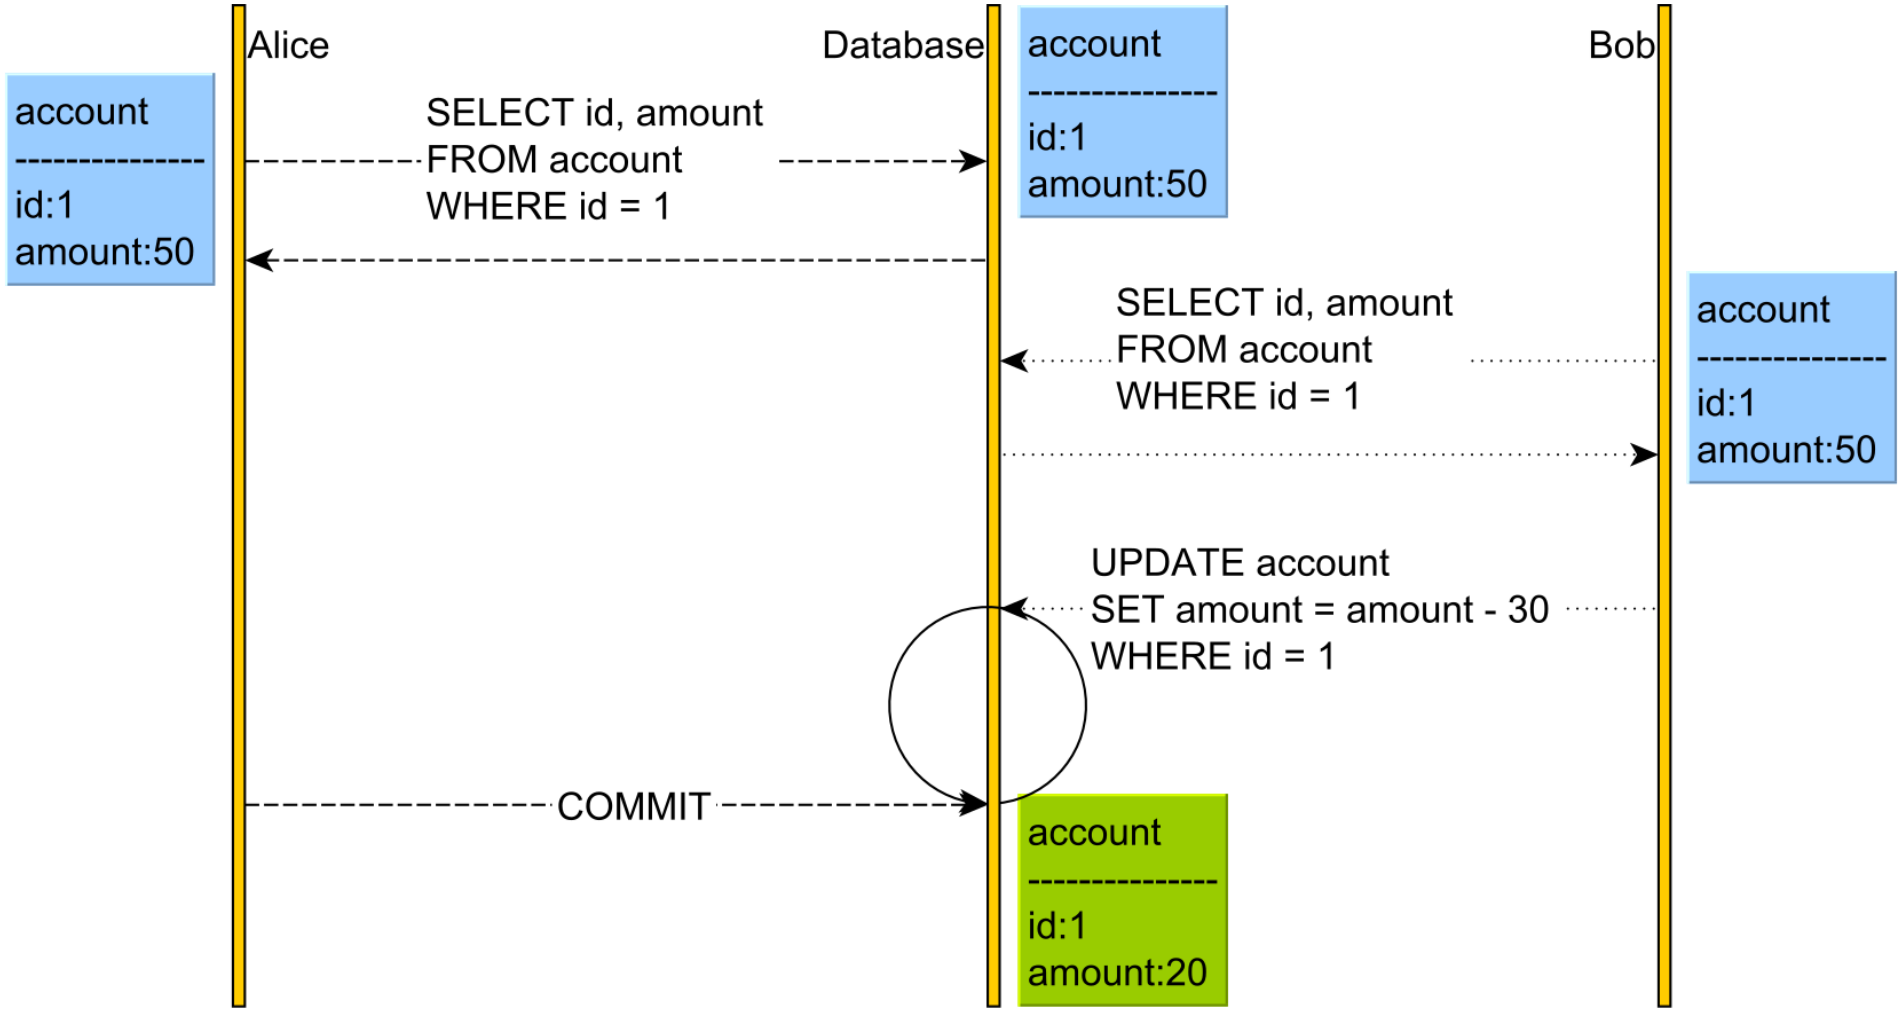

Verrouillage Optimiste

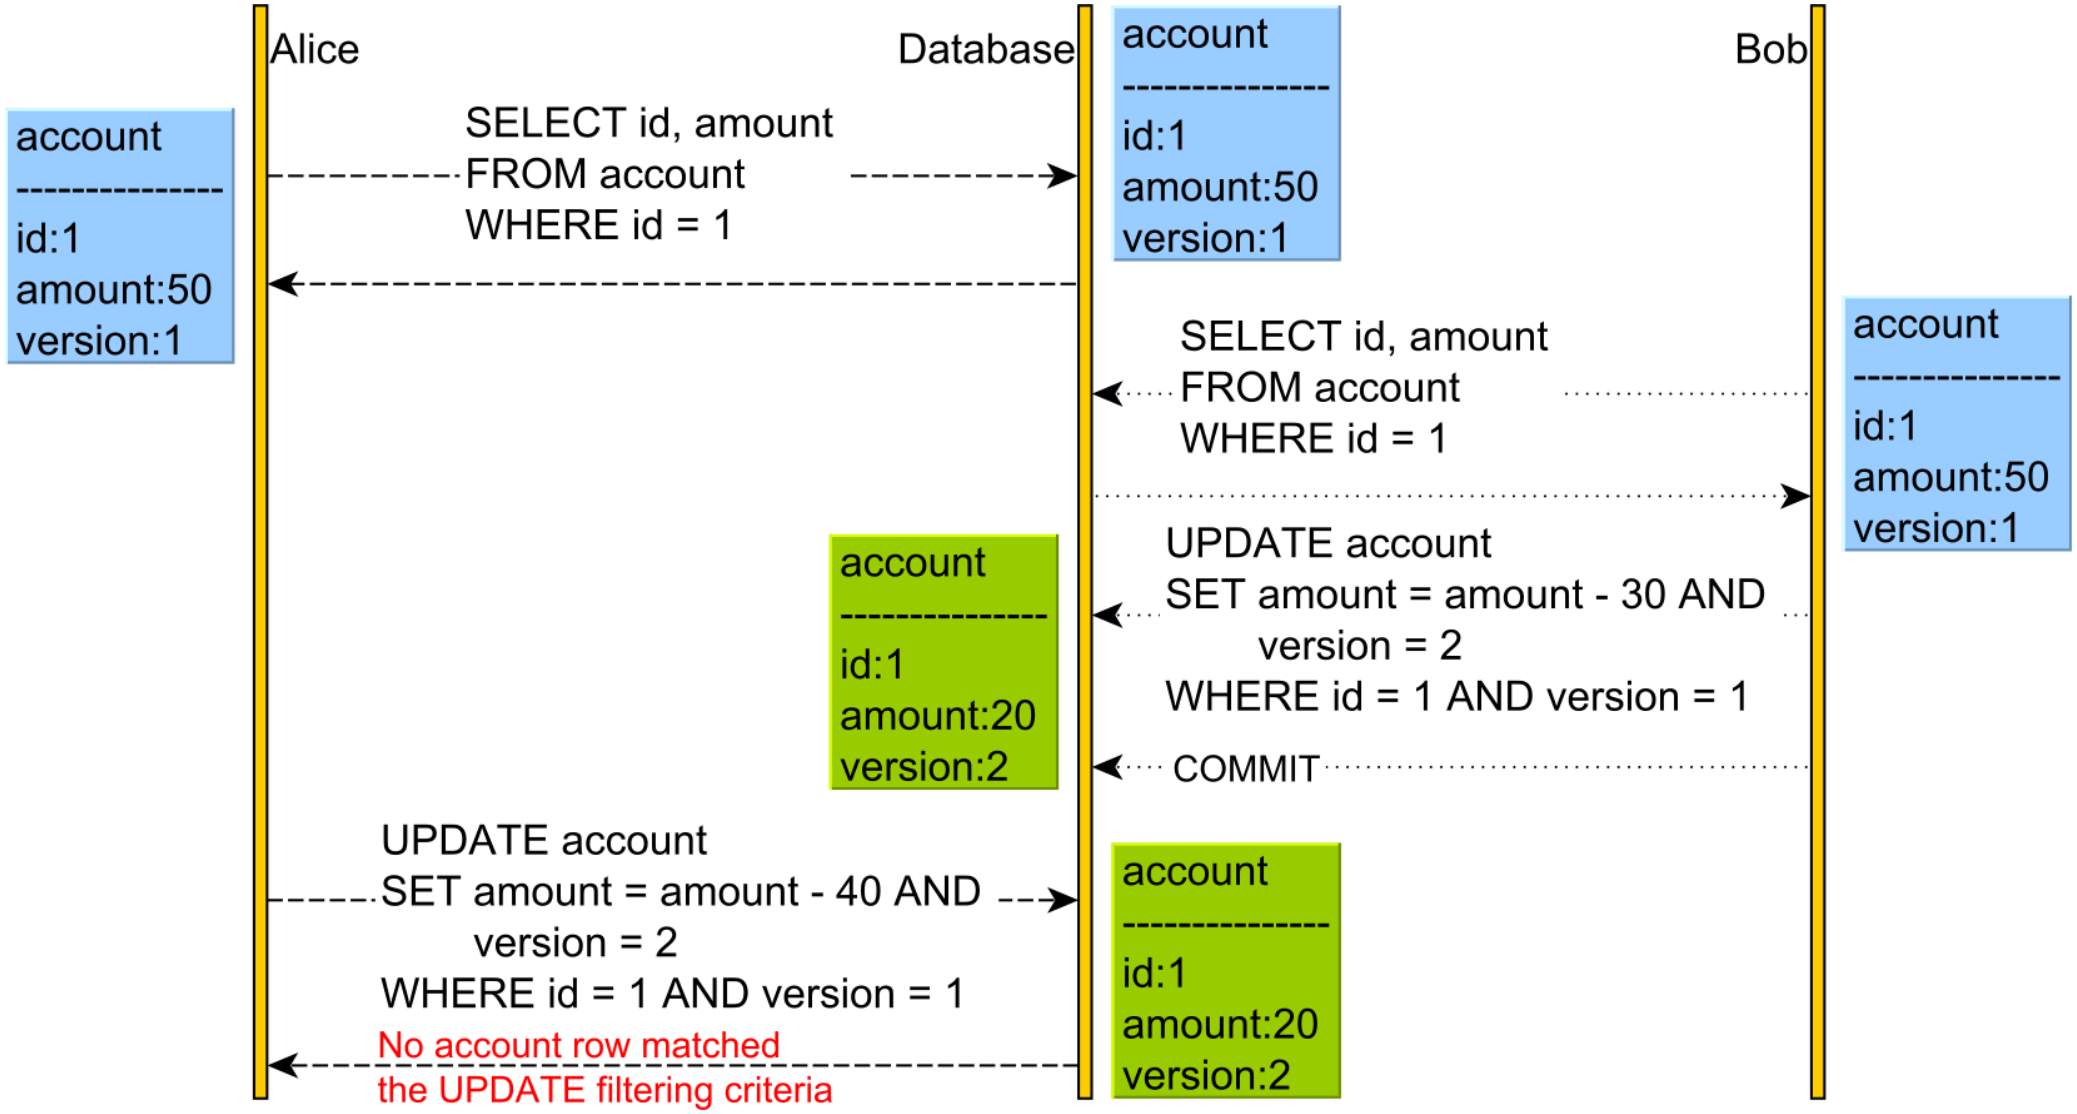

Théorème de CAP : 3 propriétés

- ***Consistency*** **(Cohérence)** :

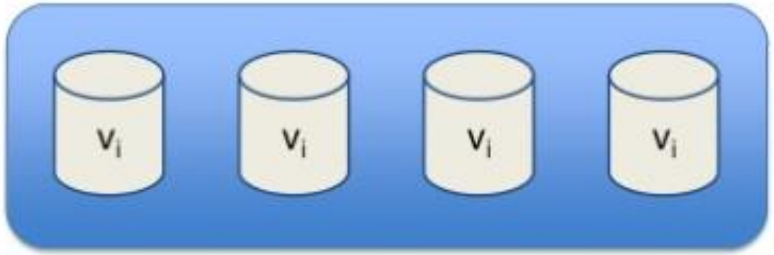

- ***Availability*** **(Disponibilité)** :

- ***Partition Tolerance*** **(Distribution ou Tolérance au partitionnement)** :

©Maude Manouvrier - Univ. Paris-Dauphine – Figure reprise de https://www.slideshare.net/YoavFrancis/cap-theorem-theory-implications-and-practices

Théorème de CAP : détails des propriétés

- Proposé par Eric A. Brewer en 2000
- Définition de **3 propriétés** :
  - ***Consistency* (Cohérence)** : Une donnée n'a qu'un seul état visible quel que soit le nombre de réplicas - tous les nœuds du système voient exactement les mêmes données au même moment
  - ***Availability* (Disponibilité)** : Tant que le système tourne (distribué ou non), la donnée doit être disponible - garantie que toutes les requêtes reçoivent une réponse
  - ***Partition Tolerance* (Distribution ou Tolérance au partitionnement)** : Quel que soit le nombre de serveurs, toute requête doit fournir un résultat correct - aucune panne moins importante qu'une coupure totale du réseau ne doit empêcher le système de répondre correctement (ou encore : en cas de morcellement en sous-réseaux, chacun doit pouvoir fonctionner de manière autonome)

Repris er adapté de https://openclassrooms.com/en/courses/4462426-maitrisez-les-bases-de-donnees-nosql/4462471-maitrisez-le-theoreme-de-cap et wikipedia

©Maude Manouvrier - Univ. Paris-Dauphine

Théorème de CAP : exemples

“Dans toute base de données, on ne peut respecter au plus que 2 propriétés parmi la cohérence, la disponibilité et la distribution “

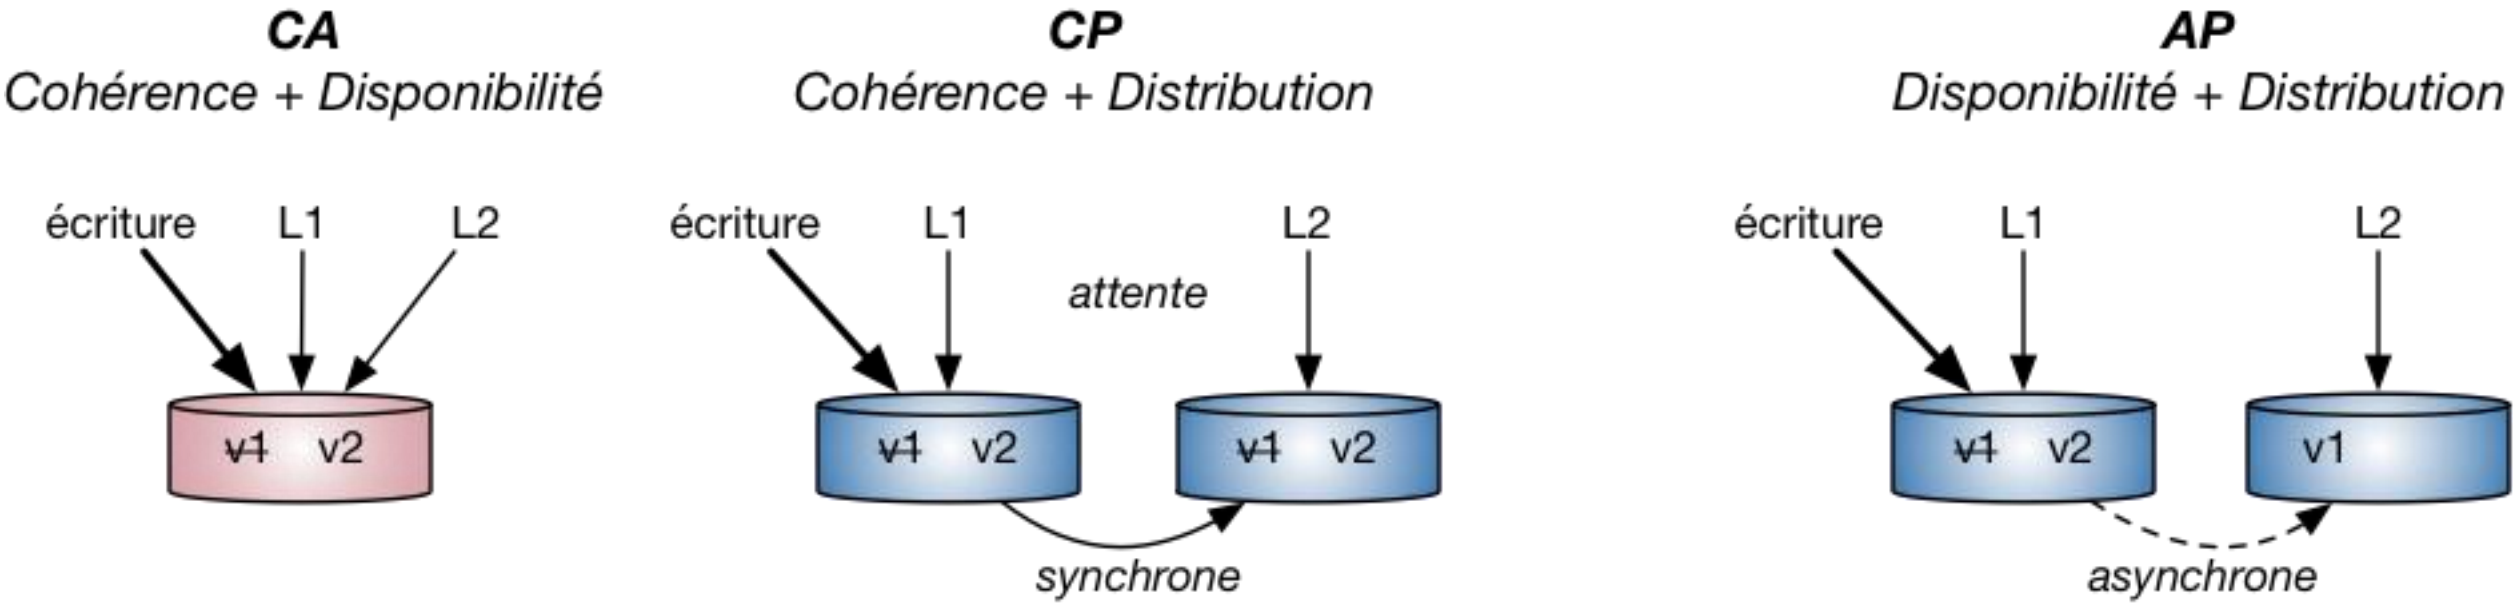

Repris er adapté de https://openclassrooms.com/en/courses/4462426-maitrisez-les-bases-de-donnees-nosql/4462471-maitrisez-le-theoreme-de-cap

©Maude Manouvrier - Univ. Paris-Dauphine

Positionnement SQL/NoSQL selon CAP

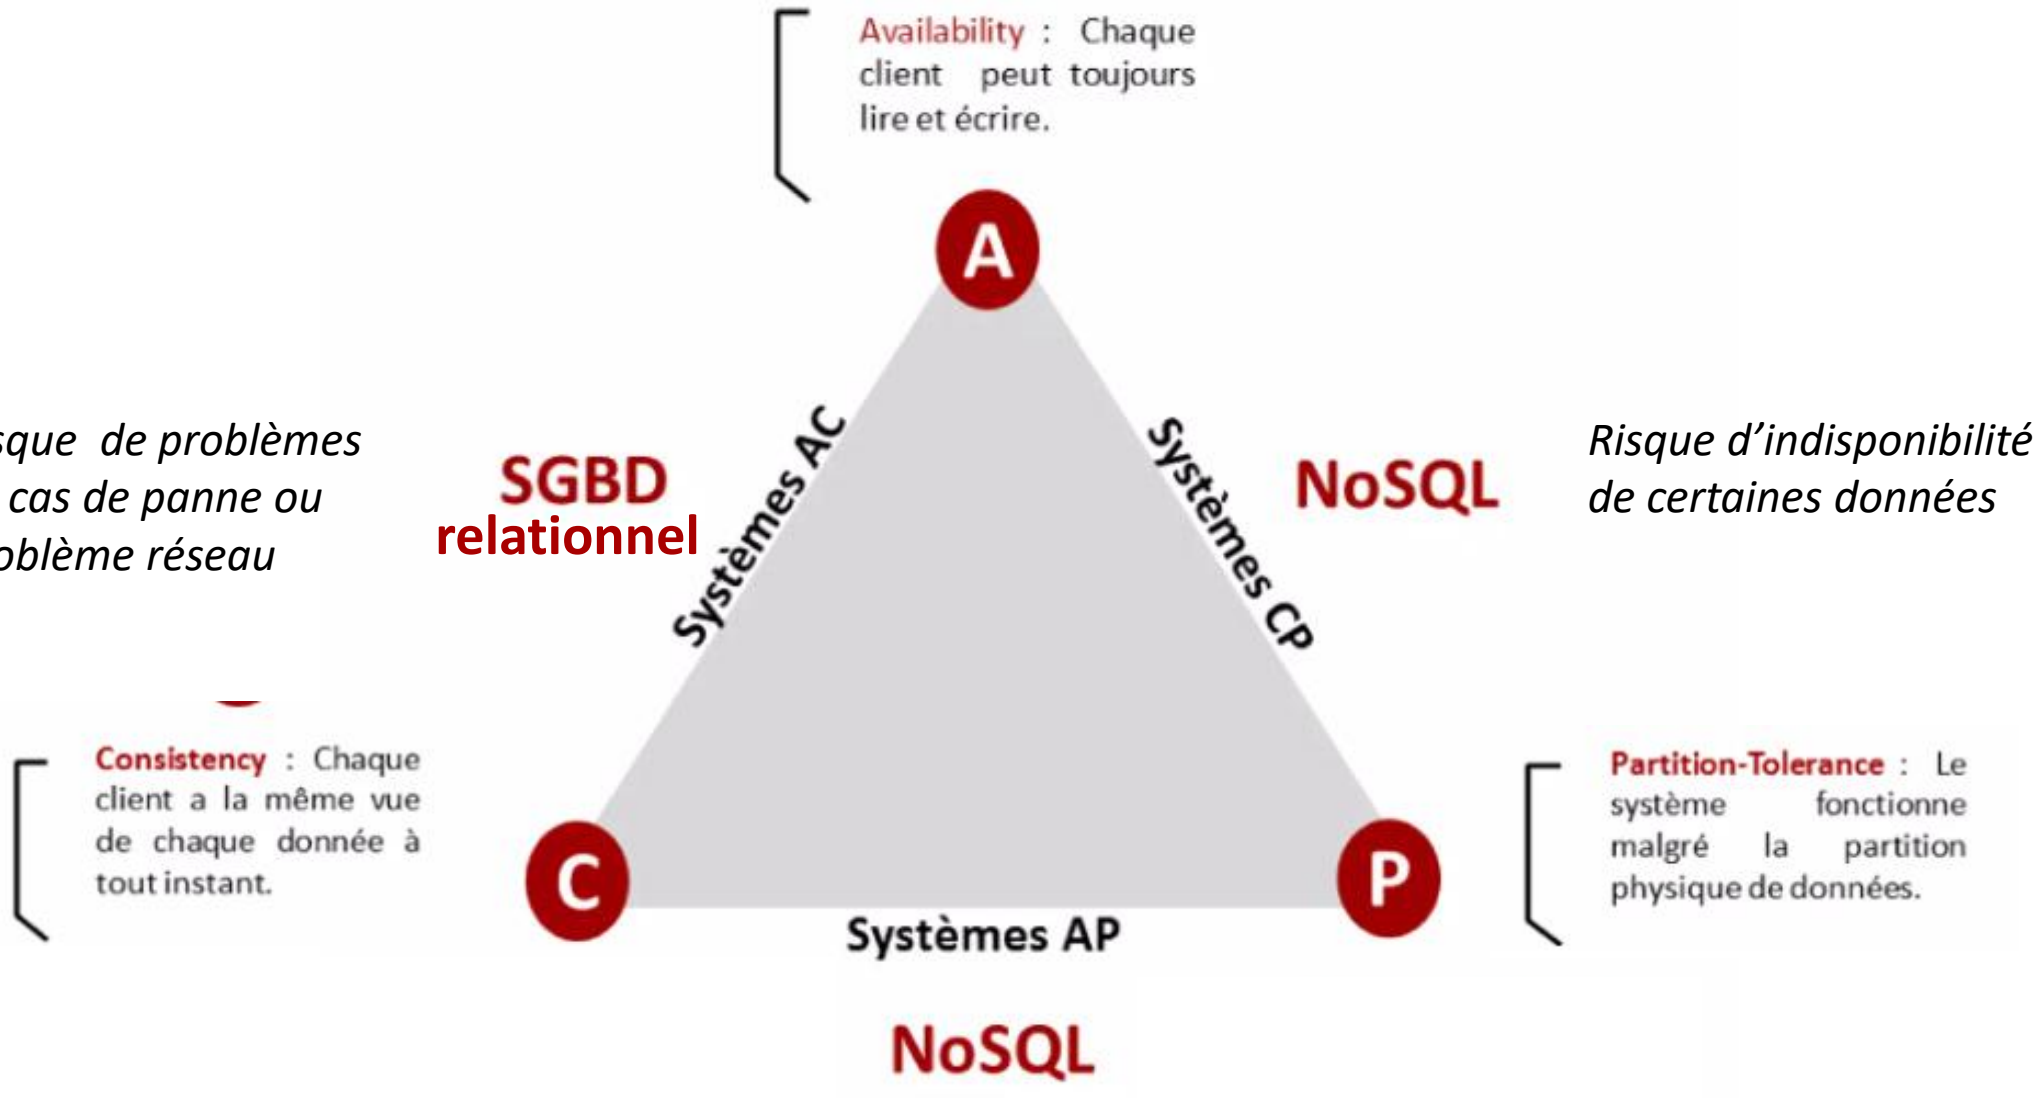

©Maude Manouvrier - Univ. Paris-Dauphine – Figure reprise et adapté de https://fr.slideshare.net/MinyarHidri/les-bd-nosql