

Cryptographie dans les bases de données

Nicolas Anciaux, SMIS project
INRIA Paris-Rocquencourt - France

Nicolas.Anciaux@inria.fr

Slides from: N. Anciaux, L. Bouganim, P. Pucheral, A. Canteaut

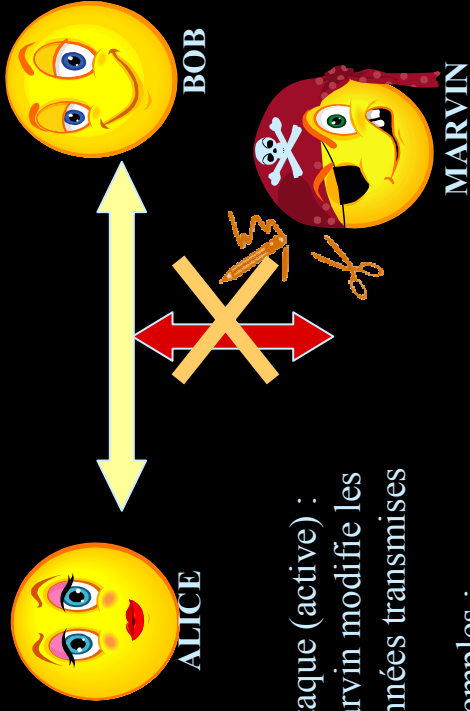
Plan

- Outils cryptographiques
- Application du chiffrement à une base de données
- L'approche serveur
- L'approche client
- L'approche par matériel sûr (exotique...)
- Conclusion

Cryptographie : intégrité et confidentialité

Protection de l'intégrité:

- Hachage des messages




Attaque (active) :
Marvin modifie les
données transmises

Exemples :

1. Vol d'identité
2. Altération
3. Forgerie
4. Rejeu
5. Repudiation
6. Destruction
7. Retard/réordonnement

Protection de la confidentialité:

- Chiffrement des messages



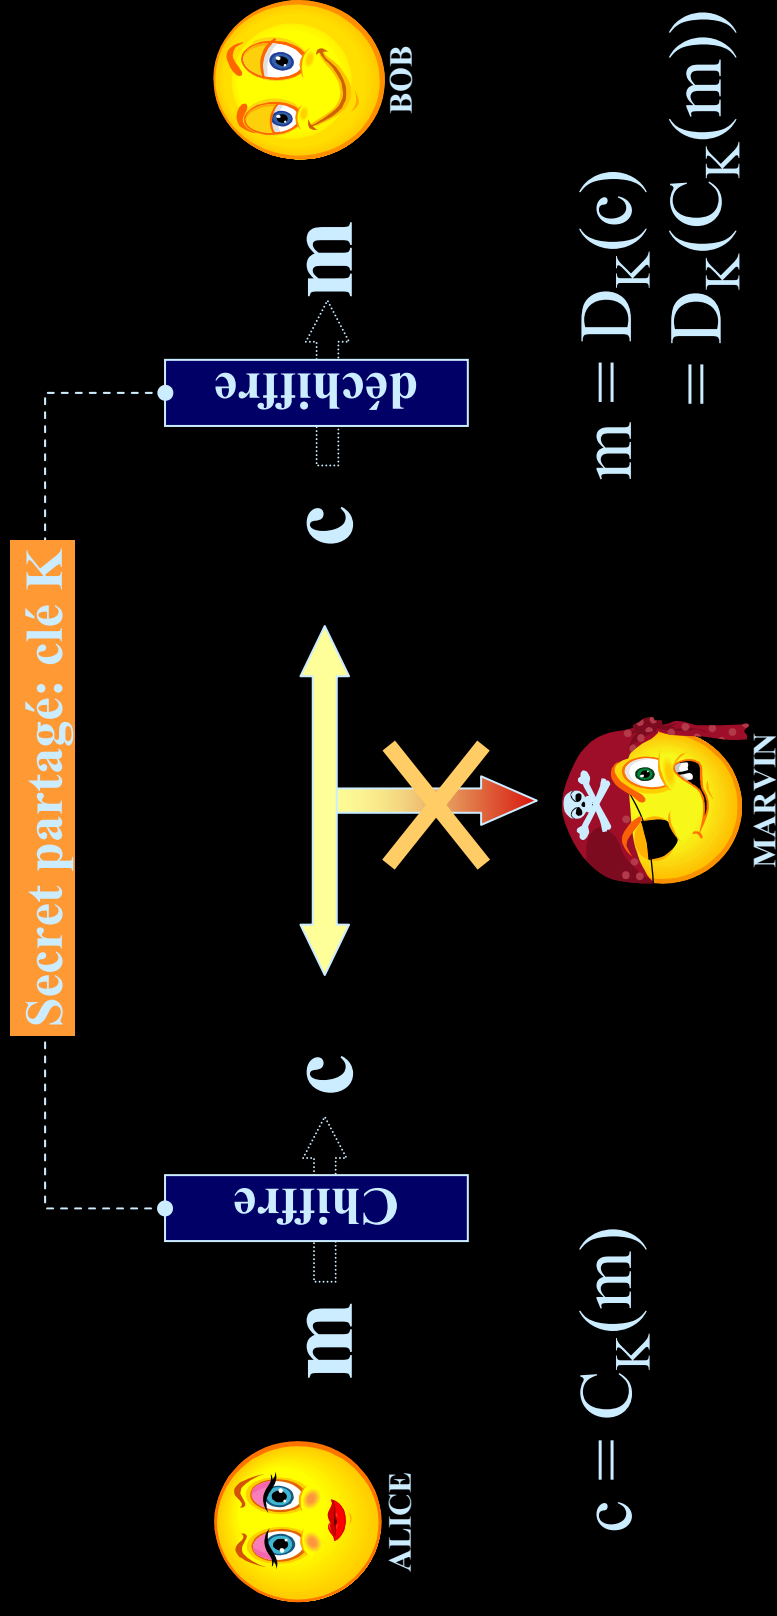
Attaque (passive) :
Marvin accède au
contenu des messages

Hachage cryptographique

- Une fonction de hachage cryptographique
 - transforme un message de taille quelconque en une empreinte de taille fixe;
 - doit être facile à calculer.
- ... de plus, elle a les propriétés suivantes:
 - La fonction est difficile à inverser (à sens unique)
 - Il est difficile de trouver 2 messages de même empreinte (sans collision)
- Ainsi, toute modification du message génère une modification de l'empreinte
- Exemples d'algorithmes
 - Message Digest 5 (MD5), résultat sur 128 bits
 - Secure Hash Algorithm 1 (SHA-1), résultat sur 160 bits
- La fonction de hachage peut utiliser une clé cryptographique (authentification)
 - ... et/ou être combinée avec une fonction de chiffrement

Chiffrement Symétrique (“à clé secrète”)

- Auteur et destinataire des messages partagent un secret
- Le secret (clé) permet de chiffrer et le déchiffrer les messages
- La sécurité repose sur ce seul secret (tout le reste est publique)



Algorithmes et attaques

Des algorithmes symétriques par bloc et des attaques

- **DES**
 - Data Encryption Standard (1976 - 1997)
 - Chiffrement par bloc de 64 bits
 - Chiffrement/déchiffrement = même algorithme
 - La clé fait 56 bits
- **3DES**
 - Remplace DES entre 1997 et 2001
 - Nécessite 3 clés de 56 bits
 - $3DES(k_1, k_2, k_3, M) = DES(k_3, DES(k_2, DES(k_1, M)))$
- **RIJNDAEL (AES)**
 - Utilisé depuis 2001 (standard depuis 2002)
 - Chiffrement par bloc de 128 bits
 - La clé fait 128, 192 ou 256 bits
 - Rapide, nécessite peu de mémoire

- 1997: 39 jours sur 10 000 Pentium
- 1998: une clé DES cassée en 56h (pour 250 000 \$)
- 2007: 6.4 jours sur une machine parallèle (\$10,000)

- La meilleure attaque connue nécessite 2^{32} messages clairs connus, 2^{113} étapes, 2^{90} chiffrements DES, et 2^{88} mémoire !!
- 3DES est sûr (actuellement)

- Seules des attaques canal latéral ont été réussies sur AES
- Voir www.cryptosystem.net/aes/ pour information
- AES est sûr (actuellement)

➔ Puis-je chiffrer avec 3DES ou AES sans problème ?

Plan

- Outils cryptographiques
- Application du chiffrement à une base de données
- L'approche serveur
- L'approche client
- L'approche par matériel sûr (exotique...)
- Conclusion

Application du chiffrement au contexte BD

- **Si je chiffre une BD avec un algorithme sûr, le résultat est-il sûr ?**
- Les algorithmes de chiffrement résistent aux attaques suivantes:
 - Meme si l'attaquant connait le texte chiffré c , il ne peut ni trouver le message m en clair, ni trouver la clé K
 - Meme si l'attaquant connait des couples clair/chiffré (m, c) , il ne peut ni trouver la clé K , ni obtenir d'autres messages en clair
- **... mais pas toujours leur mise en oeuvre (mode opérateur/protocole)**
- **Le contexte BD a des spécificités difficiles à prendre en compte**
 - Gros volume de données
 - Motifs répétés, distribution qui peuvent être connues
 - Données modifiables

Mauvais choix du mode opératoire


- Mode ECB \Rightarrow attaque par analyse de fréquence
 - ECB : Motif en clair identiques \Rightarrow motif chiffré identique
- 
- Mode CTR  \Rightarrow attaque par comparaisons successives
 - CTR : $m \text{ XOR } m' = D_K(m) \text{ XOR } D_K(m) \Rightarrow$ information sur le contenu des MAJ !

\rightarrow Si je chiffre une BD avec un algorithme sûr, le résultat est-il sûr ? NON...

- \rightarrow Les spécificités du contexte BD doivent être prises en compte...
- \rightarrow Quid des “concessions” faites à la sécurité pour raisons de perf.?

Chiffrer à quel niveau ? (1/3)

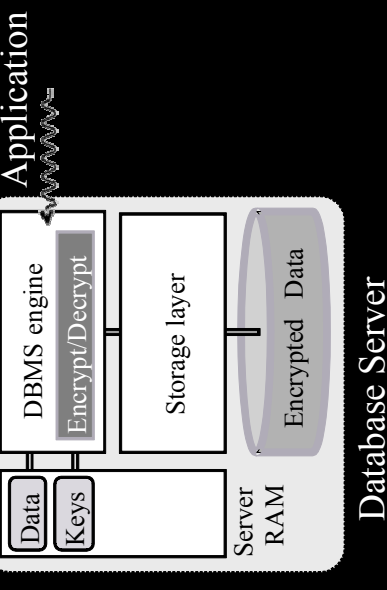
- Chiffrement niveau OS (chiffrement fichiers/stockage)



- ✚ Transparent pour le SGBD et l'application
- ... mais chiffrement non sélectif → des limites
 - Chiffrement non lié au droits d'accès (1 clé par privilège)
 - Chiffrement partiel proscrit (=> performances?)

Chiffrer à quel niveau ? (2/3)

11

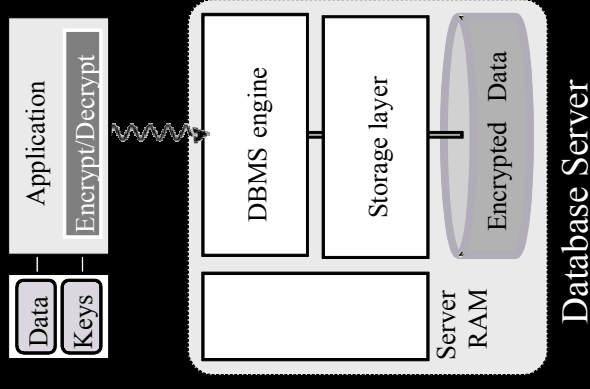


- **Chiffrement niveau SGBD**
 - + Chiffrement sélectif (spécifique)
 - Chiffrer selon les privilèges utilisateur
 - Chiffrer les données les plus sensibles
 - au niveau table, ligne, colonne...
 - ... de façon conditionnelle (salaire >10K)
- + **Transparence pour l'application**
- ... mais mécanismes internes SGBD à révisiter
 - Evaluation de requête + indexation sur des données chiffrées impossible
 - sauf chiffrement à propriétés particulières (préservant égalité ou l'ordre => dangereux pour la sécurité)
 - Surtout dans un contexte où le serveur n'est pas de confiance (approche client)
- ... et problème de performance en perspective

Chiffrer à quel niveau ? (3/3)

- **Chiffrement niveau application**
 - ✚ Résistance aux attaques internes
 - Aucune transparence pour l'application
 - L'application pilote de chiffrement/déchiffrement
 - Et gère les clés...
 - Le SGBD ne peut traiter les données déchiffrées
 - Au risque d'attaques internes
- **Dégradation importante des performances**
 - L'application prend à sa charge une (grande) partie de l'évaluation de requête
- **Le client peut attaquer les droits d'accès**
 - Les données et les clés sont en clair sur le client

Conclusion : chiffrement dans le SGBD 😊



Chiffrement au niveau SGBD : approches


- Le SGBD protège l’empreinte disque contre:
 - Observation de données
 - Altération des données
 - Substitution des données
 - Rejeu d’anciennes version des données
- Différentes approches:
 - Approche serveur :
 - Le serveur protège les données (Chiffrement/déchiffrement/hachage)
 - Approche client
 - Le client protège les données
 - Approches à base de matériel sûr (MS)
 - Le MS protège les données

Plan

- Outils cryptographiques
- Application du chiffrement à une base de données
- L'approche serveur
- L'approche client
- L'approche par matériel sûr (exotique...)
- Conclusion

L'approche serveur : principe

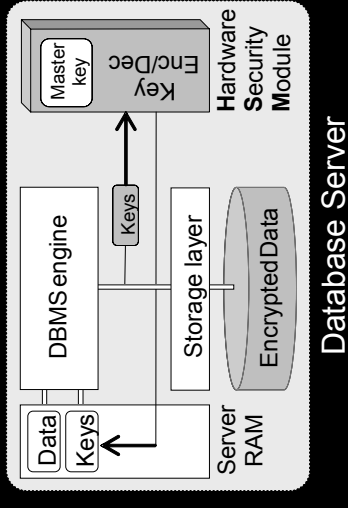
- Le serveur chiffre/déchiffre/hache les données
 - Les clés sont détenues par le serveur
 - Les données sont déchiffrées lors de l'évaluation des requêtes
- La BD est protégées sur le support de stockage persistant
 - Le niveau de protection des données n'excède pas celle celui des clés, stockées sur le serveur
 - Solution Oracle: les clés sont chiffrées par une *master key* chiffrée elle-même avec un mot de passe administrateur (*wallet*)
- Faiblesses : attaques internes
 - Attaque administrateur (le DBA a tous les droits)
 - Peut accéder aux clés/données et utiliser la base
 - Ceci sans laisser de traces



L'approche serveur : gestion des clés

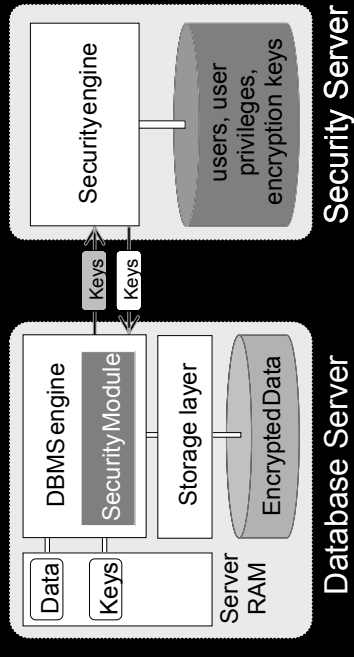
- Techniques réduisant au maximum
 - l'exposition des clés
 - Et les droits de l'administrateur
- Introduction d'un dispositif sécurisé (HSM, Hardware Security Module)

- ✚ Les clés ne sont accessibles que pendant l'exécution
- Elles sont chiffrées avec une « master key », dans le HSM
- ▬ ... mais les clés restent exposées (brièvement)
- ... et les données sont en clair lors de l'exécution



- Introduction d'un serveur de sécurité (serveur distinct)

- Un 2ème serveur gère les clés et droits d'accès
 - 2ème Admin : Grant/revoke/create user...
- ✚ Résiste « mieux » aux attaques internes
 - Le DBA/tyroan ne peut pas observer l'empreinte de la BD
- ▬ Mais les clés/données restent en clair à l'exécution



Approche serveur: solutions commerciales (1)

- L'exemple d'Oracle
 - DBMS Obfuscation Toolkit (8i) :
 - Solution de chiffrement niveau application
 - À base de procédures stockées (chiffrement/déchiffrement/hachage)
 - Transparent Data Encryption (TDE) :
 - Solution de chiffrement niveau SGBD
 - SQL étendu à la gestion du chiffrement
 - Master key : chiffrée par un mot de passe (admin.) ou stockée dans un HSM
 - Chiffrement niveau attribut (10g)
 - Colonnes sensibles chiffrées : dans les tablespaces (même temporaires), SGA, logs/backups...
 - Indexation des prédicats d'égalité (chiffrement NO_SALT) → attaque par analyse de fréquence !
 - Chiffrement niveau Tablespace (11g)
 - Tablespaces complets chiffrés sur disque, déchiffré en SGA
 - Indexation classique (indexés fabriqués sur le clair)
- SQL server 2008 TDE : similaire à Oracle TDE / chiffrement niveau Tablespace

Approche serveur: solutions commerciales (2)

- Protegrity Secure.Data
 - Basé sur une solution de chiffrement serveur
 - Pour tout SGBD : Oracle, SQL Server, IBM DB2 ...
 - Ajout d'un serveur de sécurité
 - Secure.Manager : gestion des utilisateurs, droits et clés
 - Secure.Server : module de chiffrement intégré au noyau SGBD
 - ... et 2 personnes physiques différentes ...
 - Database Administrator (DBA) / Security Administrator (SA)
- IBM DB2 Data Encryption Expert : similaire à Protegrity

L'approche serveur : conclusion

- L'empreinte de la BD est chiffrée
 - Attention au concession sur la sécurité pour les performance (indexation)
- Les clés sont exposées au minimum
 - HSM => exposition brève lors de l'exécution
- Les droits de l'administrateurs sont réduits au maximum
 - Serveur de sécurité => la DBA n'a plus « tous » les droits
- Mais :
 - Données en clair lors de l'exécution
 - Clés détenues ou transmises au serveur
- Limite de l'approche serveur
 - Le serveur n'est pas un site de confiance
 - Vulnérable aux attaques internes (administrateur / insider / troyan)


Plan

- Outils cryptographiques
- Application du chiffrement à une base de données
- L'approche serveur
- L'approche client
- L'approche par matériel sûr (exotique...)
- Conclusion

L'approche client : principe

- **Chiffrement coté client**
 - Pas de transmission du clair ni des clés au serveur
 - Le traitement s'effectue sur le client (pire cas)
- **La BD est protégée coté serveur**
 - Le serveur résiste aux attaques internes
 - Mais... dégradation très importante des performances

→ Problème : déporter la majeure partie du traitement sur le serveur (données chiffrées), sans perte de sécurité
- **Limites de l'approche client :**
 - Gestionnaire de droit côté client
 - Données et clés en clair sur le client
 - Or le client n'est pas forcément un site de confiance
 - Donc ne convient pas à une BD partagée (BD privée uniquement)



Réponses au problème de performance

- Indexation des données
 - Indexation (index traditionnel chiffré)
 - Ex. Le client maintient et utilise (traverse) un B+-Tree [DDJ+03]
 - Etiquetage des tuples
 - Ex. Le client pose des étiquettes, pour sélectionner/joindre [HIL+02]
- **Modèle de chiffrement**
 - ... indexer des données chiffrées ne sert à rien 😊
 - ... traiter directement les données chiffrées est impossibles 😊
 - SAUF SI: on dispose de chiffrement à propriétés particulières
 - Ex. Préservant l'égalité [Ora07, BoP02], l'ordre [AKS+04], ou homomorphiques [GeZ07]
 - Compromis sécurité / performance...

Solution par étiquetage [HILL+02]

- Granule de chiffrement = tuple
- Ajout d'étiquettes d'attributs
 - Indique l'appartenance d'un attribut d'un tuple à une plage de valeurs
 - Permet des traitements approximatifs sur le serveur
 - Sélection, jointure, groupement

tuple:



tuple chiffré:

Attributs numériques

- Partitionner le domaine de variation d'un attribut
 - Chaque partition contient un nombre identique de tuples


Connaissance du client

$h(1)=17$	$h(2)=4$	$h(3)=12$	$h(4)=3$	$h(5)=6$	$h(6)=1$	$h(7)=9$
20	24	31	35	40	48	50
						54
						Age=53

Connaissance du serveur

	I_{Age}
(Age=37)	3
(Age=53)	9
(Age=26)	4

$32 < \text{Age} < 40$



Attributes « String »

- Signatures de string (n-grams)

Connaissance du client

$N = \{ "g", "re", "ma" \}$


string	signature
'Greencar'	110
'Bigrecordman'	111
'Bigman'	101

Connaissance du serveur

I_{Name}

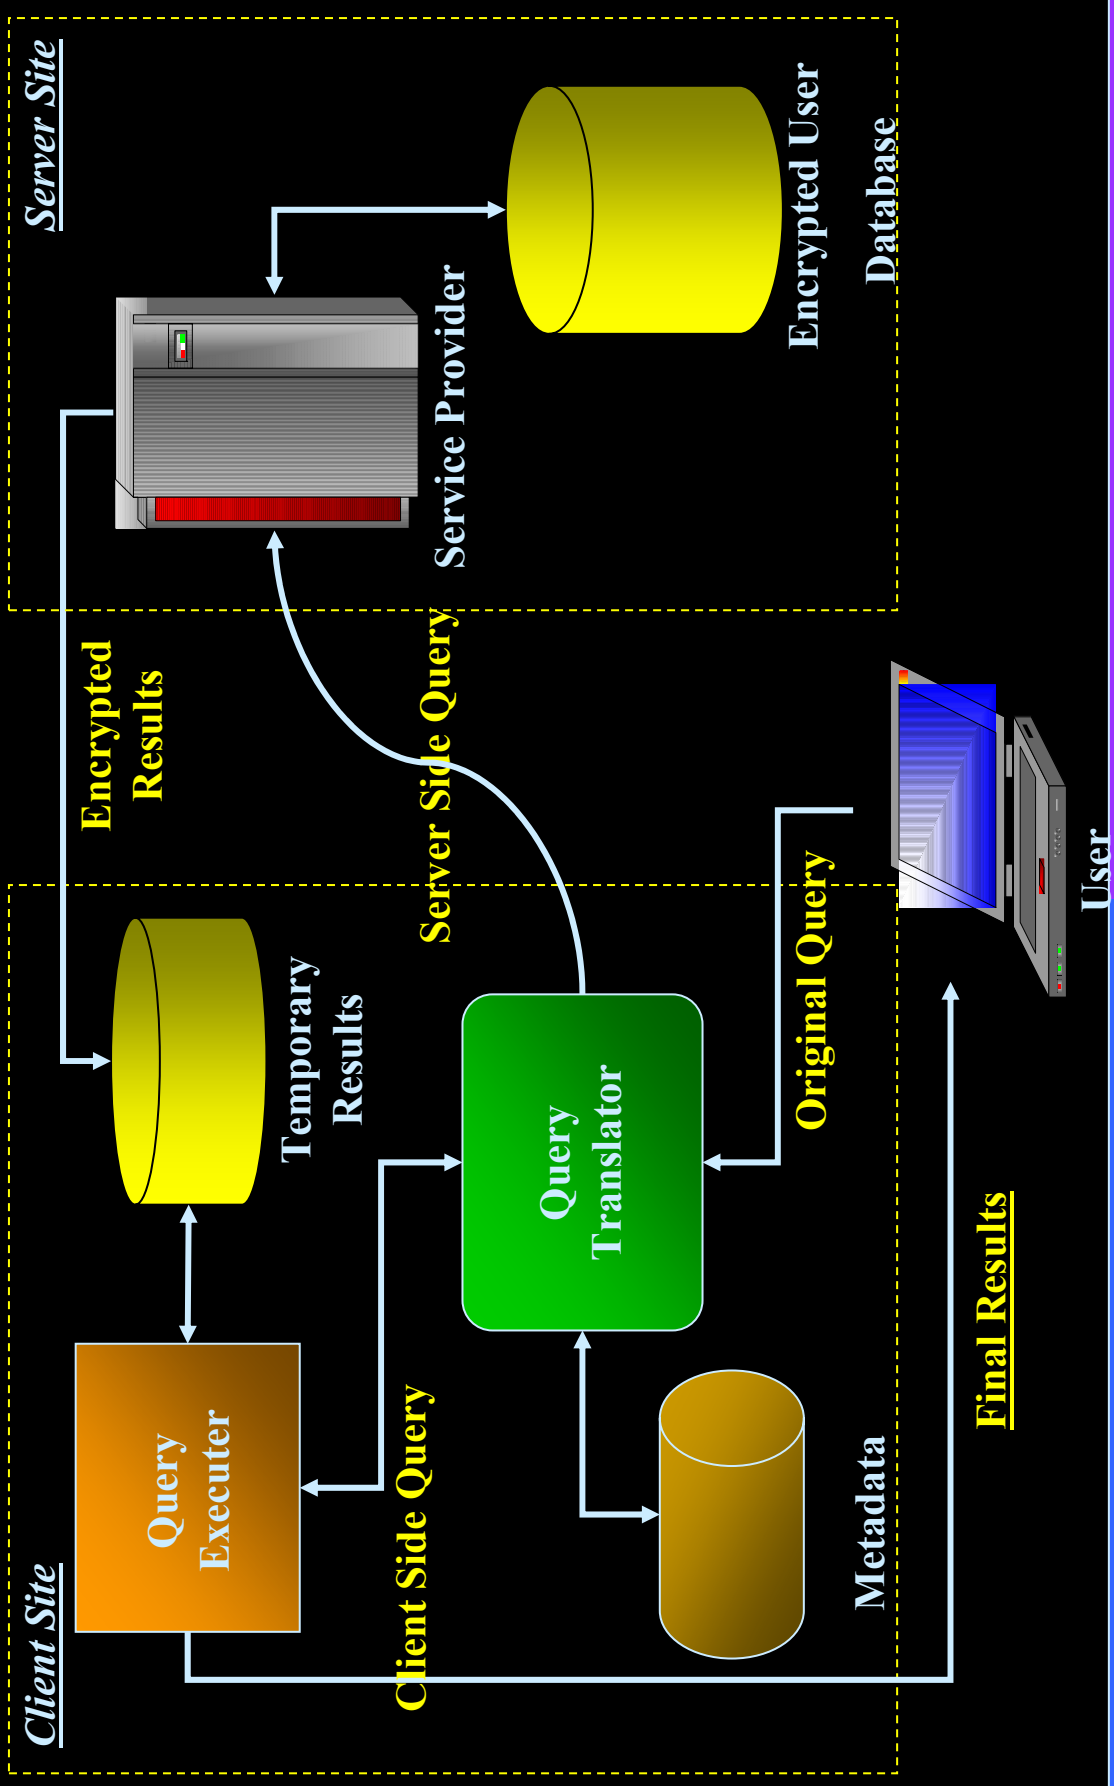
E(R1)	110
E(R2)	111
E(R3)	101

name LIKE '%green%'



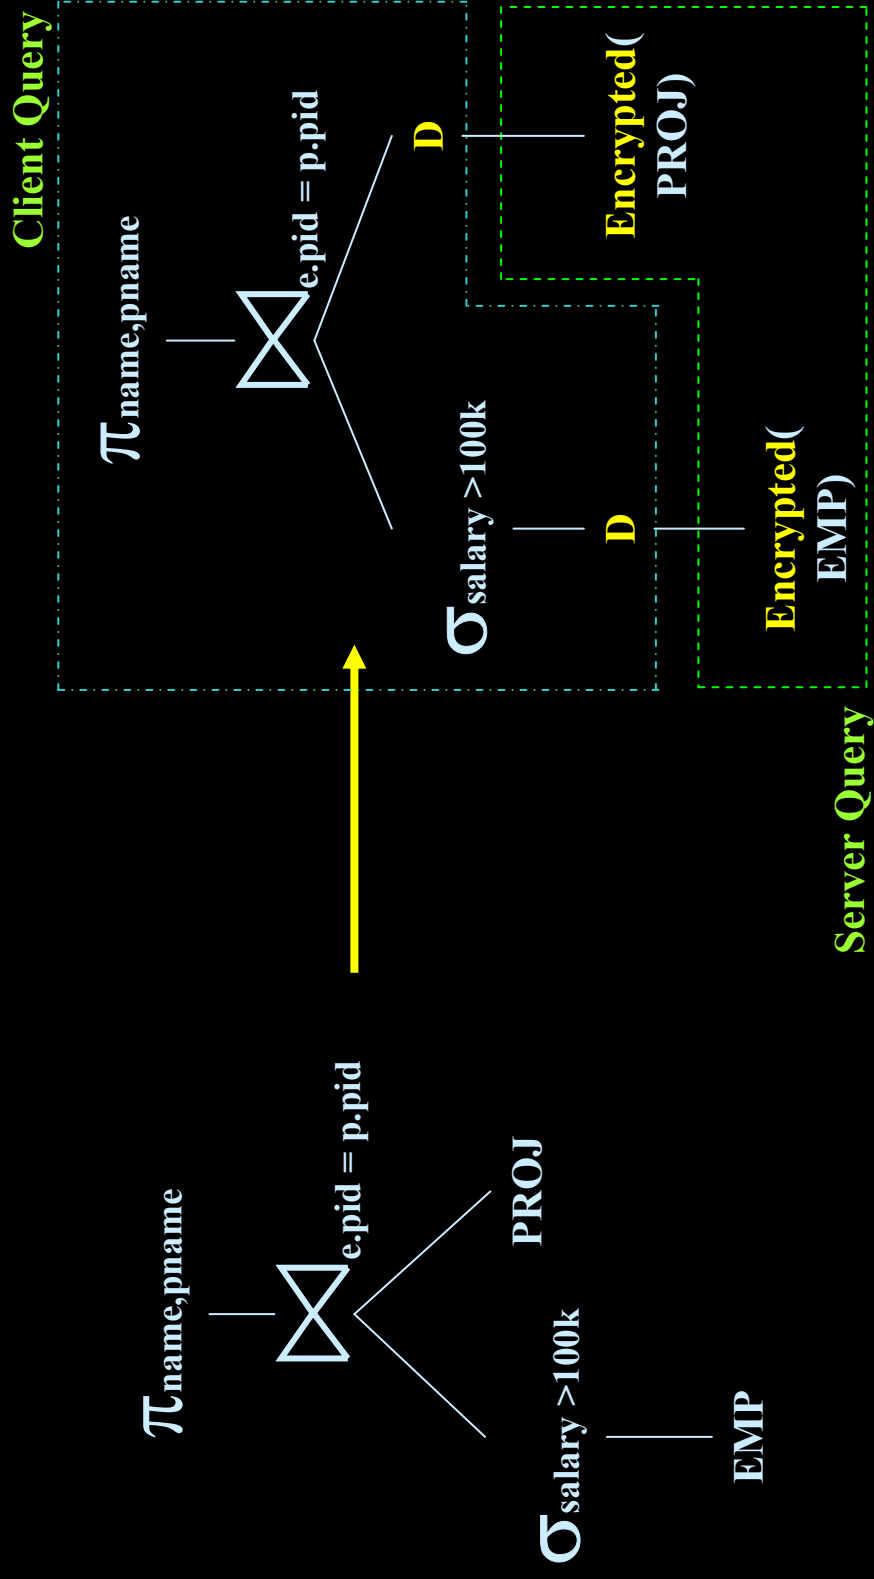
I_{Name} in (110, 111)

Architecture

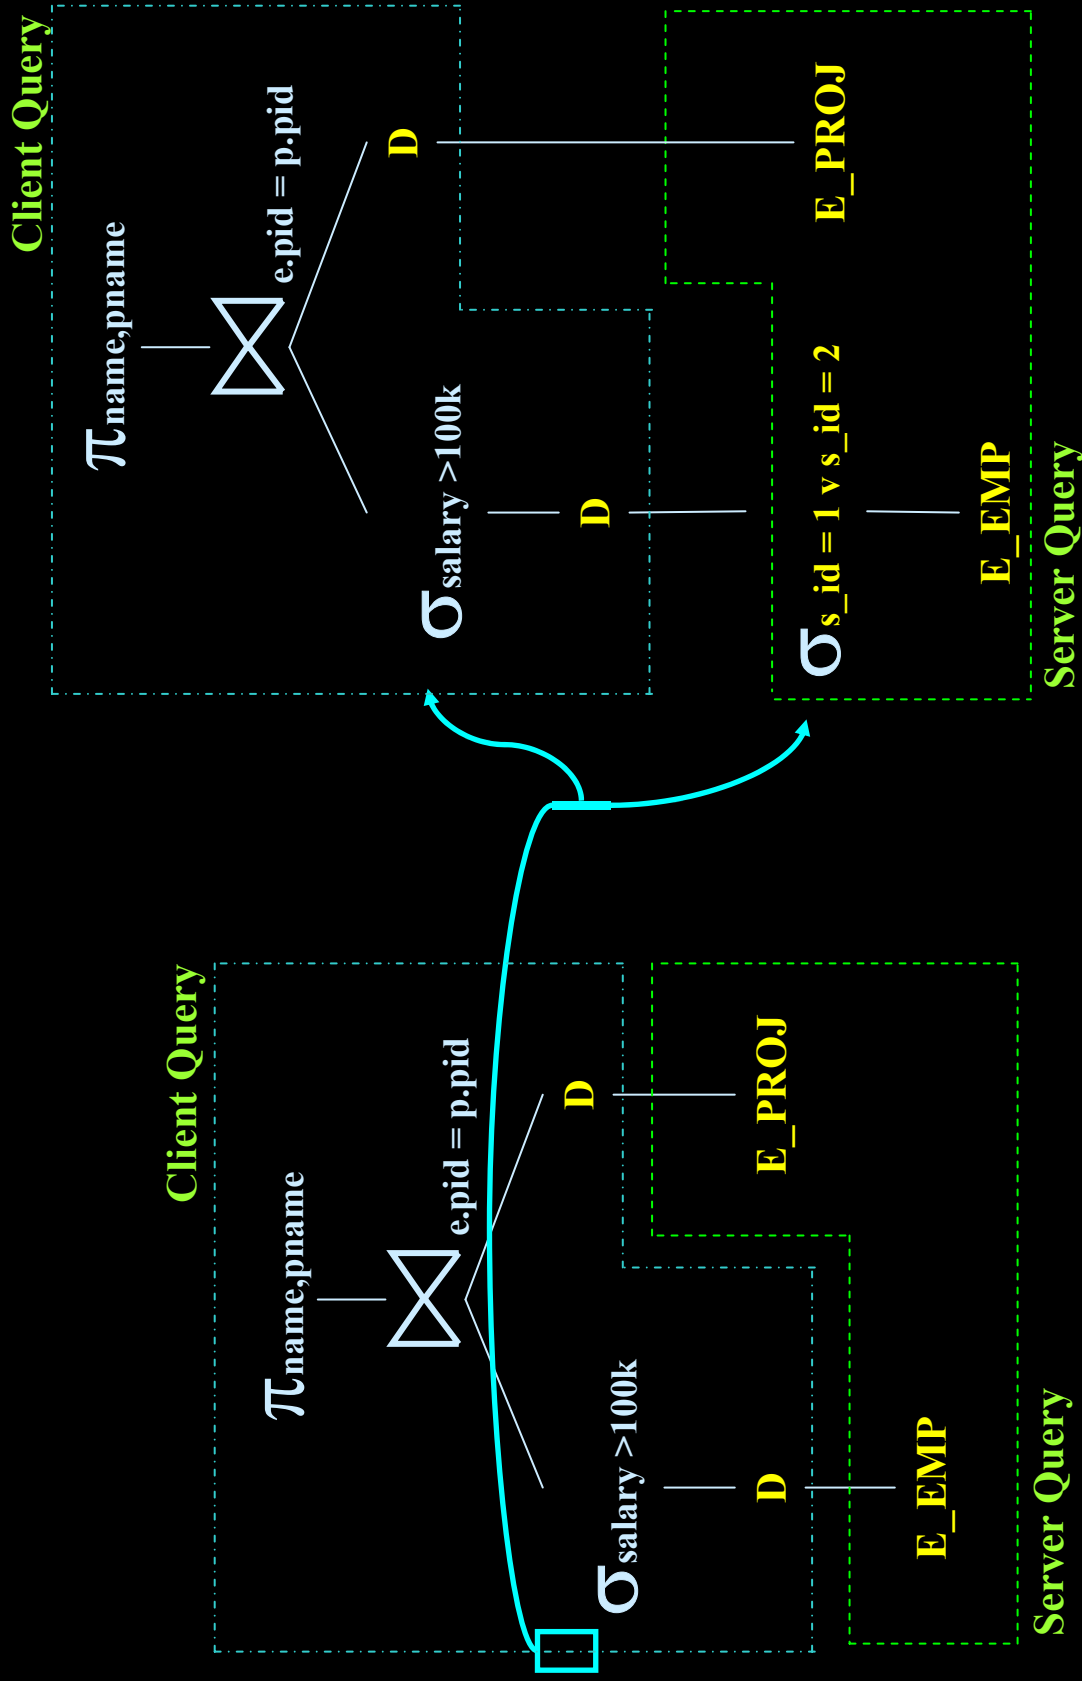


Décomposition de requête (1)

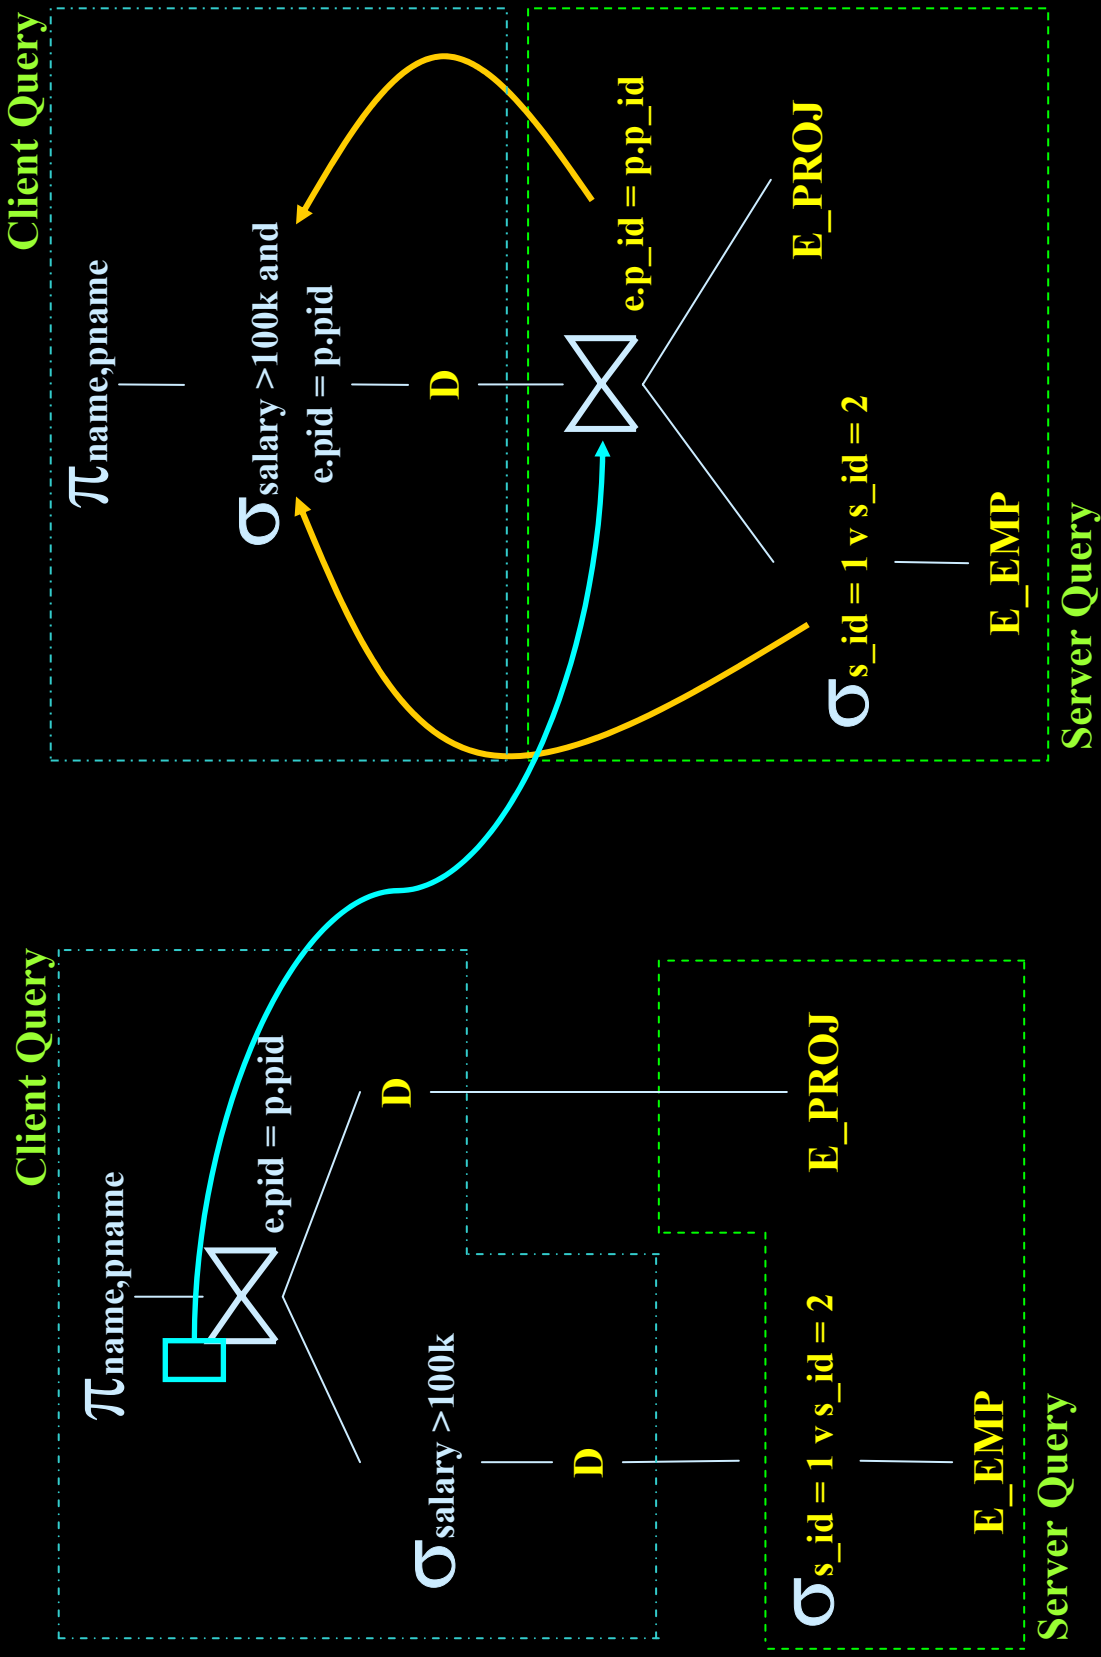
Q: SELECT name, pname FROM emp, proj
WHERE emp.pid=proj.pid AND salary > 100k



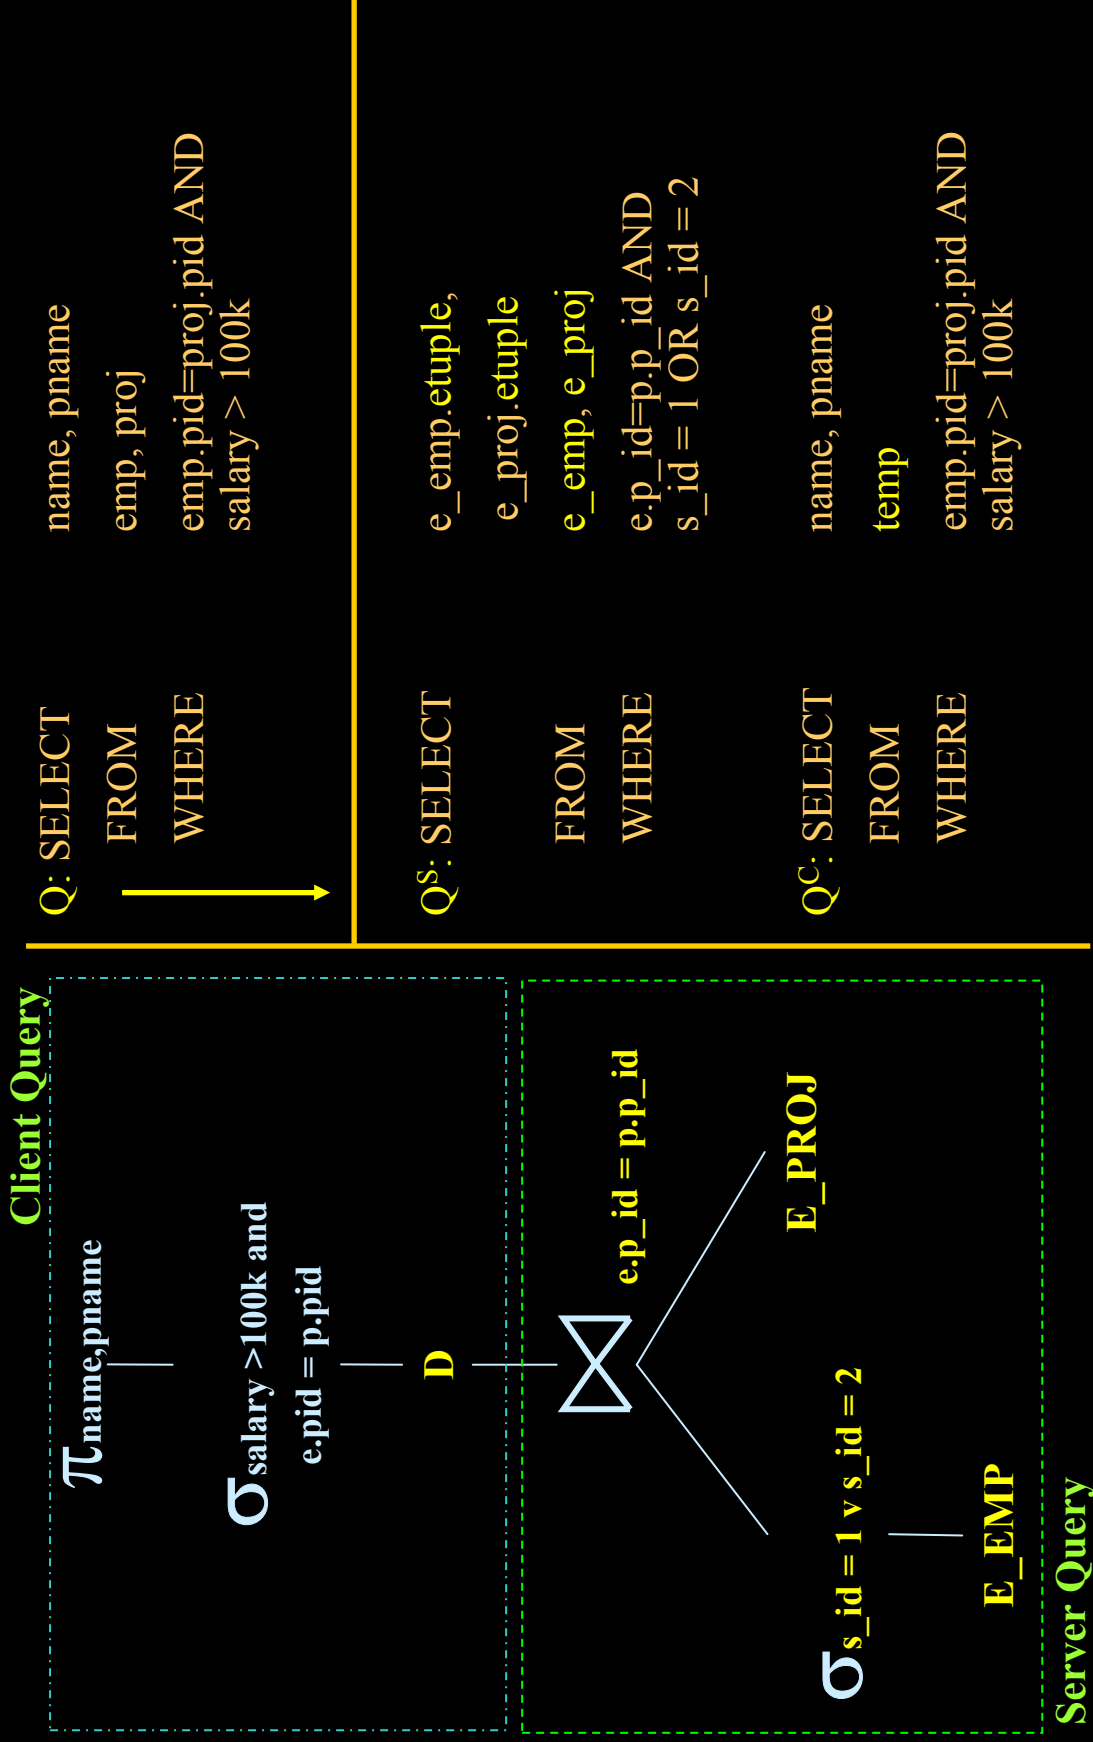
Décomposition de requête (2)



Décomposition de requête (3)



Décomposition de requête (4)



Plan

- Outils cryptographiques
- Application du chiffrement à une base de données
- L'approche serveur
- L'approche client
- L'approche par matériel sûr
- Conclusion

L'approche à base de matériel sûr (MS)

- **MS sur le client**
 - Résiste aux attaques sur le client
 - Gestionnaire de droits, clés, données en clair
- **Des instances**
 - Chip sécurisé embarqué dans une clé USB
 - Carte à puce + serveur
 - Carte SIM + téléphone
- **Problématique**
 - Traitement BD embarqué – chip extrêmement contraint (RAM)
 - Ex. C-SDA [BoP02]

Chiffrement de la BD [BoP02]

- Approche pionnière (avec des défauts!)
- Données et méta-données chiffrées
 - Hypothèse initiale : chiffrement de granule attribut, préservant l'égalité
- Seuls les clients sont habilités à Créer/Détruire/Modifier des données
- Chiffrement partiel possible

ref	nom	type	prix
d300	Dell	Pentium3	9800
I260	IBM	Pentium2	6400
...




sdz	azds	sdeefa	zze
zszd	dedef	zarevgzd	Fffe
df'g	Sde	iukéfsa	dgss
...

Traitement d'une requête complexe

Terminal

1 Trouver la moyenne des prix des produits de type = "Pentium3"

Moyenne
9400



4 Calcul de la moyenne

Serveur

2 Trouver le zze des lqskdqqs de sdeefa = "zarevgzd"



zze
Fffe
z'z'et

La partie des requêtes non évaluable sur les données chiffrées est évaluée sur la carte (prédicats <, >, fonctions de calcul, etc..)

Conclusion

- **Approche serveur**
 - Solution des grands éditeurs
 - Non résistant aux attaques internes
 - Problème de résistance aux attaques
 - Indexation des colonnes chiffrées => chiffrement préservant l'ordre
 - Problèmes de perfs
- **Approche client**
 - Les problèmes sont décuplés
 - Résiste aux attaques internes
 - Ne résiste pas aux attaques du client => BD privées
 - Beaucoup de problèmes de recherche
 - Indexation, étiquetage, modèle de chiffrement
 - Evaluation de requêtes complexes, mises à jour
- **Approche par matériel sûr : pour l'instant confiné à la recherche**

Panorama et perspectives : chiffrement


Domaine	Problème de recherche	Bibliographie (en annexe)
Chiffrement de BD (approche client, avec matériel sûr)	Modèle d'indexation pour BD chiffrée: indexes chiffrés et étiquetage, execution distribuée client/serveur...	BD relationnelle : [1_xx] BD XML : [2_xx] Avec MS : [3_xx]
Recherche d'information et sécurité (email, moteur de recherche, etc.)	Modèle de chiffrement pour BD: préservant égalité/ordre/homomorphisme, indexation sur les données chiffrées, execution centralisée, compromis sécurité/performances...	[4_xx]
Système de gestion de fichiers	Recherche dans des données chiffrées (SED, Search Encrypted Data), indexation par mots clés, chiffrement symétrique/asymétrique...	symétrique: [5_xx] asymétrique: [6_xx]
	Authentification, gestion de clés, partage sécurisé de fichiers	[7_xx]
	Chiffrement transparent	[8_xx]

Bibliographie (partielle)

- [DDJ+03] E. Damiani, S. De Capitani Vimercati, S. Jajodia, S. Paraboschi, P. Samarati, "Balancing Confidentiality and Efficiency in Untrusted Relational DBMSs", ACM CCS, 2003.
- [HIL+2] H. Hacigumus, B. Iyer, C. Li, S. Mehrotra, "Executing SQL over Encrypted Data in the Database-Service-Provider Model", SIGMOD, 2002.
- [GeZ07] Tingjian Ge and Stan Zdonik, "Answering aggregation queries in a secure system model", VLDB, 2007.
- [Ora07] Oracle Advanced Security, Technical White Paper, Oracle Corp. 2007.
- [AKS+04] Rakesh Agrawal, Jerry Kiernan, Ramakrishnan Srikant, and Yirong Xu, "Order preserving encryption for numeric data", SIGMOD 2004
- [BoP02] Luc Bouganim and Philippe Pucheral, "Chip-secured data access: confidential data on untrusted servers", VLDB 2002
- ... voir le complément en annexe

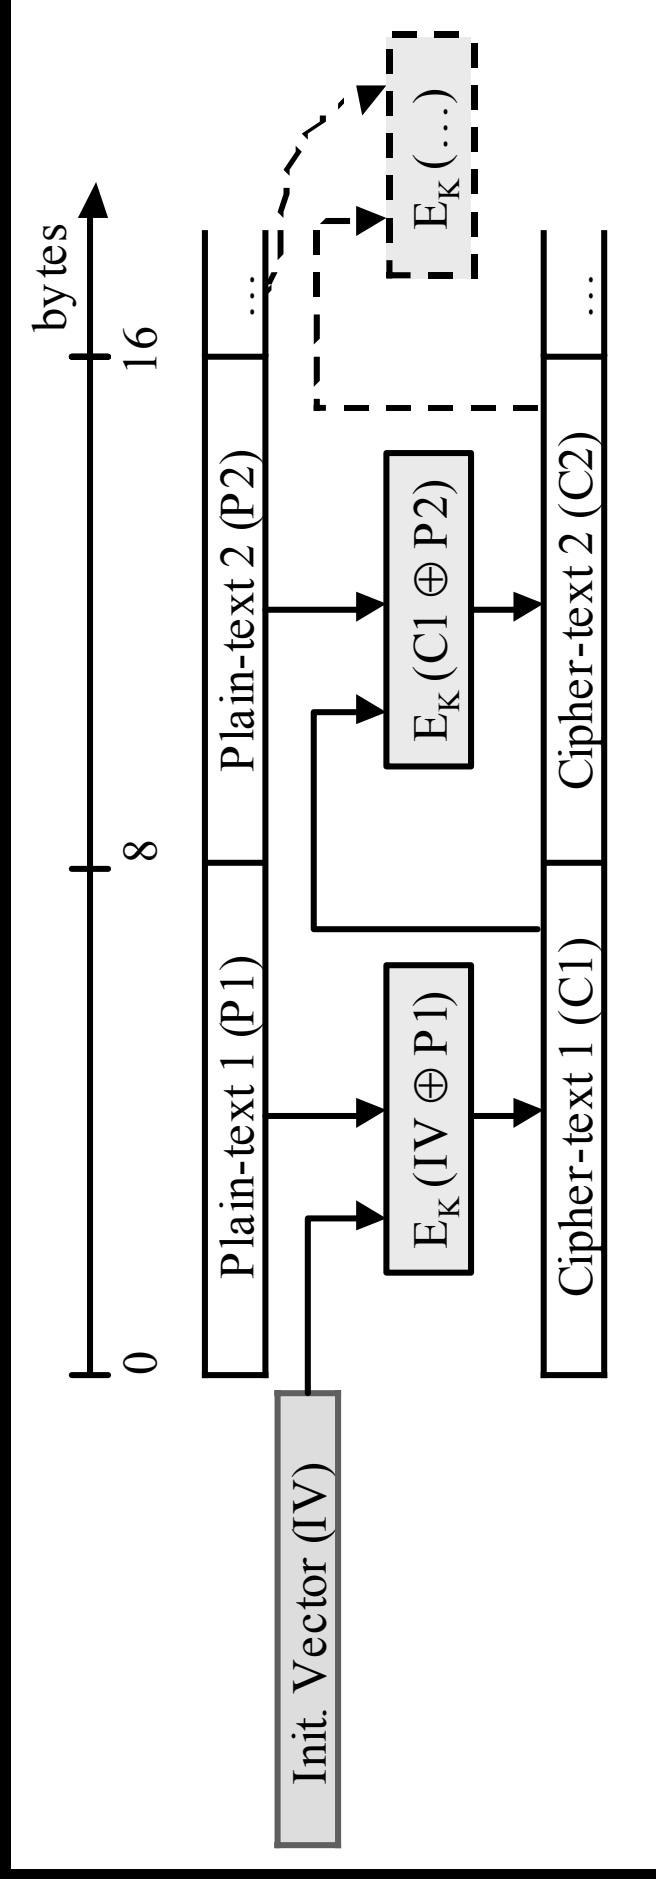
Mode opératoire ECB (Electronic Code Book)

- Les blocs sont chiffrés indépendamment



Mode opératoire CBC (Cipher Block Chaining)

- les blocs chiffrés intègrent la valeur des précédents



Mode opératoire CTR

- Résultat du XOR entre le clair et un mot aléatoire

