

# Les protocoles de Retrait d'Informations Privé (RIP)

Carlos Aguilar Melchor

XLIM - UMR CNRS 6172  
Université de Limoges

17 Février 2008

- 1 Introduction
- 2 Protocoles inconditionnellement sûrs
- 3 Protocoles calculatoirement sûrs
- 4 Applications
- 5 Conclusion

# Définitions

## Informelle

Protocole permettant à un utilisateur d'obtenir un élément d'une base de données en occultant auprès de celle-ci de quel élément il s'agit.

## Un peu plus formelle

Un protocole est dit un protocole RIP si :

- il permet aux utilisateurs d'obtenir n'importe quel élément d'une base de données, quel que soit le contenu de celle-ci ;
- pour tout couples d'éléments  $e_1, e_2$  de la base, les requêtes des utilisateurs correspondant à  $e_1$  sont indistingables de celles correspondant à  $e_2$ .

# Retrait d'Informations Privé ?

## Vous voulez dire Retrait d'Informations Privées ?

Non ! C'est le retrait qui est privé.

En anglais Private Information Retrieval (PIR). Terme ambigu :


- {Private Information} Retrieval  $\Rightarrow$  Retrait d'Informations Privées **FAUX**
- Private {Information Retrieval}  $\Rightarrow$  Retrait d'Informations Privé

La richesse de la langue française ...

## Pourquoi pas Retrait Privé d'Informations ?

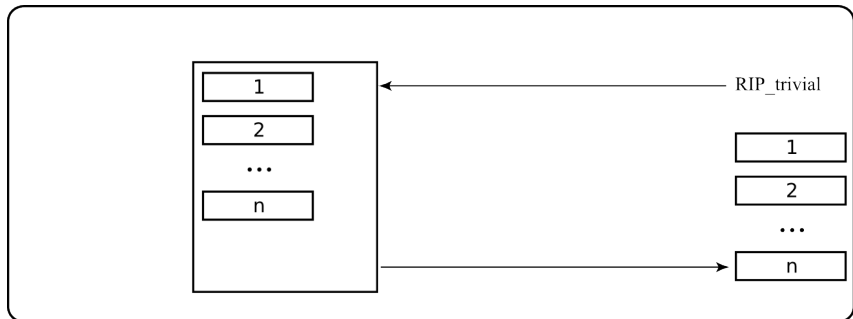
- Parce que ça peut faire penser à Retrait {Privé d'Informations} et par là à quelque chose du genre de *Zero Knowledge Retrieval* ce qui n'a rien à voir.
- Parce que RIP c'est beaucoup plus sexy que RPI :).

## Retrait traditionnel **non-privé**




- On envoie l'index  $i$  de l'élément nous intéressant.
- On reçoit l'élément en question.

## Retrait privé trivial



- On demande toute la base de données.
- On ne lit localement que l'élément nous intéressant.

# Protocole RIP



- On génère une requête pour l'élément d'index  $i$ .
- La base calcule une réponse à partir de notre requête.
- On décode la réponse et on obtient l'élément souhaité.

# Variantes

## Le RIP symétrique (SPIR)

- L'utilisateur n'obtient **aucune** information sur les autres éléments.
- Il existe des transformations génériques efficaces.

## L'*Oblivious Transfer*

- Axe de recherche existant depuis 1981 (Michael Rabin).
- Même conditions de sécurité que le RIP symétrique.
- Vise à réduire les coûts calculatoires pour l'utilisateur et le serveur.
- Comporte une étape où la BDD est envoyée intégralement (chiffrée).



# Motivations

## La base de données peut être ...

- une bibliothèque électronique, et quels livres nous lisons peut fournir des informations sur nos convictions politiques, ou certains détails de notre personnalité qu'il peut être souhaitable de garder confidentiels ;
- une base de données pharmaceutique, et certains laboratoires clients de la base peuvent désirer qu'on ne puisse pas savoir à quels principes actifs ils s'intéressent ;
- des cours d'actions, et les clients peuvent être des investisseurs ne voulant pas dévoiler quels cours ils suivent.

## La solution triviale est inacceptable si la base est ...

- de taille extrêmement importante ;
- confidentielle ;
- rapidement obsolète.

- 1 Introduction
- 2 Protocoles inconditionnellement sûrs**
- 3 Protocoles calculatoirement sûrs
- 4 Applications
- 5 Conclusion

# Chor et al., FoCS'95

## Contexte

- La base de données contient  $n$  éléments  $\{e_1, \dots, e_n\}$ , chacun de  $\ell$  bits.
- L'utilisateur veut récupérer le  $i$ -ème élément,  $e_i$ .
- Deux répliques  $BDD_1$  et  $BDD_2$  de la base de données peuvent être interrogées séparément.

## Limitations

- Ils ne peuvent exister que pour des bases de données répliquées.
- Il faut que les différentes répliques soient cohérentes.
- Ils ne sont pas inconditionnellement sûrs.

## 1 Introduction

## 2 Protocoles inconditionnellement sûrs


## 3 Protocoles calculatoirement sûrs

- Techniques transversales
- Protocoles basés sur le chiffrement homomorphe
- Protocoles basés sur les prédicats adaptatifs
- Protocoles basés sur le bruit

## 4 Applications


## 5 Conclusion

# Base commune




- La requête est habituellement composée de  $n$  éléments.
- Chaque élément de la requête est combiné à un élément de la base.
- La requête est indépendante des contenus de la base.
- La réponse peut encoder un nombre maximum de bits.

# Génération itérative des réponses




- La réponse peut encoder un nombre maximum de bits.
- La requête est indépendante des contenus de la base.
  - $\Rightarrow$  Découpage des éléments trop grands et génération itérative.

# Agrégation d'éléments




# Agrégation d'éléments



- Permet de réduire la taille de la requête d'un facteur  $F$ .
- Induit une augmentation de la taille de la réponse d'un facteur  $F$ .
- Proposé par Chor et al. pour la récupération d'un bit.
  - requête  $2n$ , réponse  $2 \Rightarrow$  requête  $2\sqrt{n}$ , réponse  $2\sqrt{n}$
- En pratique c'est rarement intéressant.

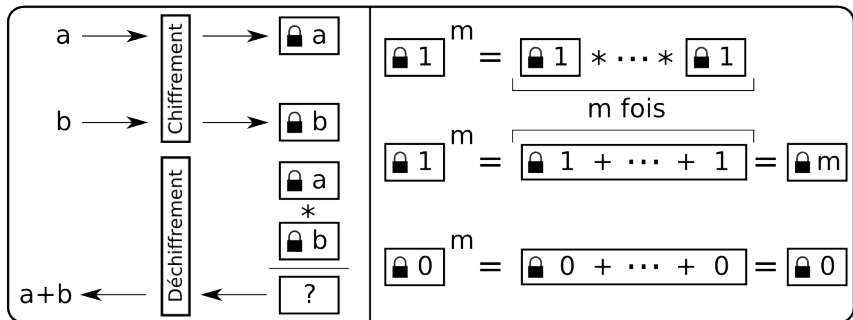


# Récursion



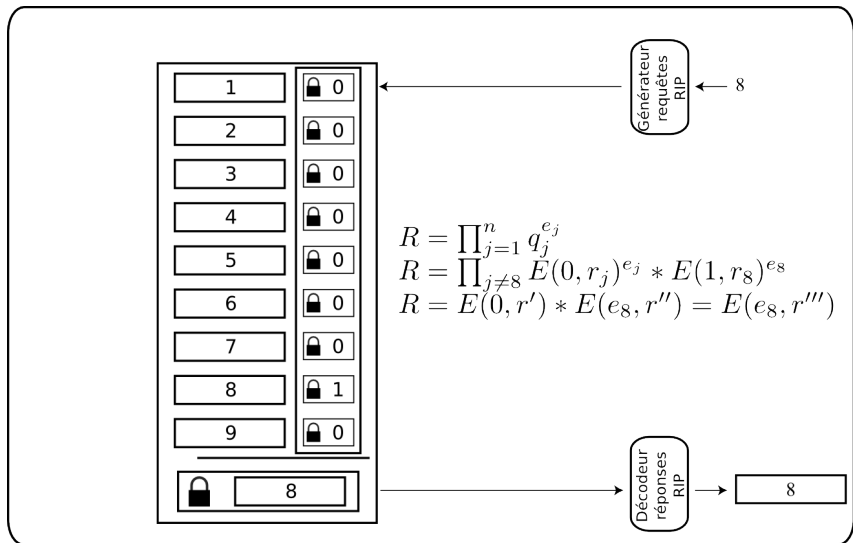
- La première requête permet d'obtenir une ligne.
- La deuxième requête opère sur la réponse générée.
  - Permet d'obtenir un élément de la ligne.
- Requête :  $2\sqrt{n}$ , facteur d'expansion de la réponse :  $F_{RIP} * F_{RIP}$ .
- Généralisation triviale  $\Rightarrow$  requête :  $d \times n^{1/d}$ , facteur d'expansion :  $F_{RIP}^d$ .

# Le chiffrement homomorphe



- Systèmes de chiffrement randomisés.
- Indistingabilité entre les chiffrés de 0 et de 1.
- Paillier EUROCRYPT'99, Damgård et Jurik ACISP'03.

# Julien P. Stern ASIACRYPT'98



# Julien P. Stern ASIACRYPT'98

## Coût des communications

- Requête :  $n$  chiffrés de 2048 bits.
- Facteur d'expansion : 2.
- Récursion  $\Rightarrow$  requête :  $2048 \times d \times n^{1/d}$ , facteur d'expansion :  $2^d$ .

## Coût calculatoire

- Facteur limitant dans les protocoles RIP : génération de la réponse.
- Coût : une multiplication modulaire de 2048 bits par bit dans la BDD.
- Traitement de la BDD à  $T = 160\text{--}490$  Kbits/s.
- Utilisateur obtient l'élément l'intéressant à  $T/n$ .
- La récursion à peu d'influence sur le coût calculatoire.

# Lipmaa ISC'05

## Idée

- Dans le protocole de Stern on chiffre avec Paillier a chaque niveau de récursion
  - On chiffre des blocs de 1024 bits et on obtient des blocs de 2048 bits.
  - $\Rightarrow$  on multiplie par 2 la taille de la réponse à chaque fois.
- Le système de chiffrement de Damgård et Jurik permet de chiffrer en passant de  $s \times 1024$  bits à  $(s + 1) \times 1024$  bits.
- Lors de premier niveau de récursion on chiffre les données par blocs de 1024 bits et on obtient des chiffrés de 2048 bits.
- Lors du deuxième niveau on chiffre les données de 2048 bits et on obtient des chiffrés de 3072 bits.
- ...

# Lipmaa ISC'05

## Coût des communications

- Requête :  $n^{1/d}$  chiffrés de 2048 bits,  $n^{1/d}$  chiffrés de 3072 bits,  $\dots$ ,  $n^{1/d}$  chiffrés de  $(d + 1) \times 1024$  bits.
- Requête :  $2048 \times ((d + 2)(d - 1)/4) \times n^{1/d}$
- Facteur d'expansion :  $1 + d$ .

## Coût calculatoire

- Les opérations au delà du premier niveau de récursion ont un coût négligeable.
- $\Rightarrow$  même coût que le protocole de Stern.

$\Rightarrow$  le protocole de Lipmaa est toujours préférable.

# Les prédicats adaptatifs

## Idée

- La requête ne change jamais, et est connue et commune à tout le monde.
  - L'utilisateur envoie une description d'un anneau fini où un élément de la requête est particulier.
  - $\Rightarrow$  seul l'élément de la BDD associé sera "absorbé".
  - La sécurité repose sur le fait que la BDD est incapable de savoir quel élément est particulier dans l'anneau.
- 
- Approche initialement proposée par Cachin Micali et Stadler à EUROCRYPT'99 sous une version peu utilisable en pratique.
  - $\Rightarrow$  Aboutissement de l'approche : Gentry et Ramzan ICALP'05.

# Gentry et Ramzan ICALP'05

## Hypothèse de sécurité *the generalized $\phi$ -hiding assumption*

Soit  $m$  un module difficile à factoriser  $g$  est un élément de l'anneau  $\mathbb{Z}/m\mathbb{Z}$  d'ordre  $\pi$  (une puissance première). Il est difficile de savoir si  $\pi$  (pour  $\log \pi < (\log \phi(m))/4$ ) divise  $\phi(m)$  ou pas à partir du couple  $(m, g)$ .

## Performances

- Requête : 2048 bits.
- Facteur d'expansion : 4.
- Coût calculatoire : une multiplication modulaire de 1024 bits par bit dans la BDD.  $\Rightarrow T = 490\text{--}1500$  Kbits/s

## Pre-calcul

- Phase de pre-calcul nécessaire.
- Coût en  $O(\ell \times n^2)$ . Deux heures pour 1000 fichiers de 2 Mo.
- Doit être relancée quand la base est actualisée.

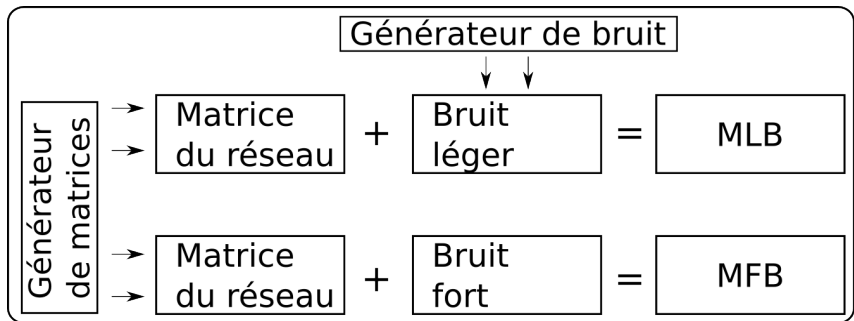


# Les protocoles basés sur le bruit

## Travaux

- Kiayias et Yung ICALP'01 : basé sur le *noisy polynomial reconstruction problem*.
  - Cassé par Bleichenbacher et al. (ICALP'03) puis par Coppersmith et Sudan (STOC'03).
- Gasarch et Yerukhimovich 2006 : basé sur le cryptosystème de Regev.
  - Donne lieu à un facteur d'expansion de l'ordre de  $3 \times 10^5$ .
  - Pas plus rapide que les protocoles basés sur le chiffrement homomorphe ou les prédicats adaptatifs.
- Aguilar et Gaborit WEWoRC'07 : basé sur des réseaux perturbés
  - Problèmes nouveaux, et donne lieu à des requêtes de grande taille.
  - Très rapide.


## Aguilar et Gaborit WeWORC'07



Hypothèse de sécurité : *the differential hidden lattice problem*

Il est difficile de distinguer les bases légèrement perturbées des bases fortement perturbées d'un réseau dont on ne connaît pas une base non perturbée.

# Aguilar et Gaborit WeWORC'07



## Génération de la réponse

Chaque scalaire de  $A$  multiplie une ligne d'une matrice de la requête.  
 $\Rightarrow$  coût par bit : une centaine de petites sommes.

# Aguilar et Gaborit WeWORC'07

## Performances en communication


- Requête :  $300 \times 10^3 \times d \times n^{1/d}$ .
- Facteur d'expansion :  $6^d$ .
- Requêtes environ 100 fois plus grandes que pour Lipmaa.
- Version soumise permettant de réduire ce facteur ...

## Coût calculatoire

Protocole	Vitesse de traitement		
	matériel à 150\$	matériel à 800\$	matériel à 1100\$
Lipmaa	160 Kbits/s	280 Kbits/s	490 Kbits/s
Gentry et Ramzan	490 Kbits/s	890 Kbits/s	1500 Kbit/s
Aguilar et Gaborit (CPU)	33 Mbits/s	130 Mbits/s	230 Mbits/s
Aguilar et Gaborit (GPU)	270 Mbits/s	1.2 Gbits/s	2 Gbits/s
Protocole trivial	Bande passante de l'utilisateur		

- 1 Introduction
- 2 Protocoles inconditionnellement sûrs
- 3 Protocoles calculatoirement sûrs
- 4 Applications**
  - Choix d'un flux de communication
  - Communications anonymes
  - Recherche par mots-clés privés
- 5 Conclusion


# Vidéo à la demande



## Contexte

- Un service de vidéo à la demande propose vingt films payants.
- Pour pouvoir voir le film en direct il est nécessaire pour l'utilisateur d'avoir un flux de 500 Kbits/s.
- Débit par utilisateur  $T / (20 * N_u)$ .
- $T = 2$  Gbits/s  $\Rightarrow$  200 utilisateurs.
- Requête :  $300 * 10^3 * 20 = 6$  Mbits.


# Serveur de VoIP



## Performances

- Aguilar et Deswarte NCA'05, NCA'06, ACSAC'07.
- Permet de communiquer anonymement à des centaines d'utilisateurs avec les protocoles classiques.
- x100 si on réduit la taille des requêtes dans notre protocole RIP.

# Serveur de VoIP




## Performances

- Aguilar et Deswarte NCA'05, NCA'06, ACSAC'07.
- Permet de communiquer anonymement à des centaines d'utilisateurs avec les protocoles classiques.
- x100 si on réduit la taille des requêtes dans notre protocole RIP.



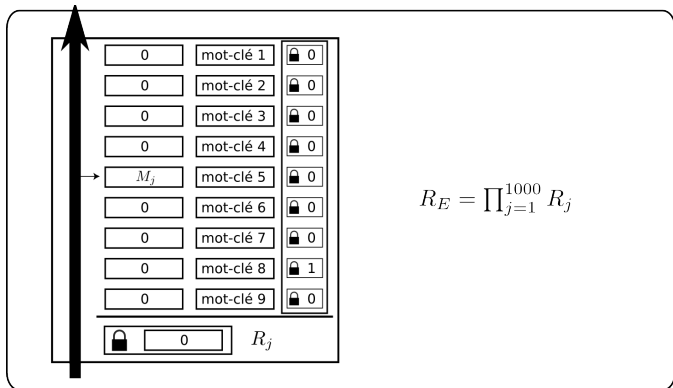
# Serveur de VoIP



## Performances

- Aguilar et Deswarte NCA'05, NCA'06, ACSAC'07.
- Permet de communiquer anonymement à des centaines d'utilisateurs avec les protocoles classiques.
- x100 si on réduit la taille des requêtes dans notre protocole RIP.

# Ostrovsky et Skeith III CRYPTO'05



$$R_E = \prod_{j=1}^{1000} R_j$$

## Performances

- Les éléments à zéro engendrent pas un coût calculatoire.
- $\Rightarrow T_L = T/C$ ,  $C$  nombre moyen de matchings par message.
- Requêtes grandes mais changent peu souvent.

- 1 Introduction
- 2 Protocoles inconditionnellement sûrs
- 3 Protocoles calculatoirement sûrs
- 4 Applications
- 5 Conclusion**

# Conclusion

- Des applications pratiques existent.
- Il faut se concentrer sur le coût calculatoire.
- L'algèbre linéaire permet d'avoir des protocoles très intéressants.

# Questions

Merci de votre attention. Des questions ?

## Bibliographie

<http://tinyurl.com/2wdlbx>

<http://freehaven.net/anonbib>