

# Filtres à mot-clés secrets et réseaux euclidiens

Carlos Aguilar Melchor<sup>2</sup>   **Laurent Fousse**<sup>1</sup>   Philippe Gaborit<sup>2</sup>

<sup>1</sup>Laboratoire J. Kuntzmann  
Université Grenoble 1

<sup>2</sup>XLIM  
Université de Limoges

26 mars 2009



MATHÉMATIQUES APPLIQUÉES - INFORMATIQUE

## 1 Problématique

- Filtre à mot-clés
- Exemple : Google Alerts

## 2 Du PIR au Private Searching

- Retrait d'information privé (PIR)
- Passage au filtre par mot-clés

## 3 Notre solution

- Principe
- Détails du chiffrement utilisé
- Performances

## 4 Conclusion



# Plan

## 1 Problématique

- Filtre à mot-clés
- Exemple : Google Alerts

## 2 Du PIR au Private Searching

- Retrait d'information privé (PIR)
- Passage au filtre par mot-clés

## 3 Notre solution

- Principe
- Détails du chiffrement utilisé
- Performances

## 4 Conclusion



# Filtre à mot-clés secrets (*Private Searching*)

## Définition informelle

Protocole permettant de faire une recherche parmi un flux de documents sans dévoiler sa requête.



# Filtre à mot-clés secrets (*Private Searching*)

## Définition informelle

Protocole permettant de faire une recherche parmi un flux de documents sans dévoiler sa requête.

## Définition plus formelle

Un obfuscateur à clef publique transforme un programme  $f$  en un couple de programmes  $(F, Dec)$  tels que

$$Dec(F(x)) = f(x)$$

pour tout  $x$  et la donnée de  $F$  ne permet pas de distinguer  $f$  de la classe de programmes considérés pour un adversaire polynomial.



# Plan

## 1 Problématique

- Filtre à mot-clés
- Exemple : Google Alerts

## 2 Du PIR au Private Searching

- Retrait d'information privé (PIR)
- Passage au filtre par mot-clés

## 3 Notre solution

- Principe
- Détails du chiffrement utilisé
- Performances

## 4 Conclusion



# Exemple de filtre *non-privé*

## Google Alerts

- Mot-clefs et adresse email soumis par formulaire ;
- Résultats envoyés périodiquement par email.



# Google Alerts



Alertes Google (version Bêta)

[Foire aux questions](#) | [Connexion](#)

## Alertes Google - Bienvenue

Les Alertes Google sont envoyées par courrier électronique quand des articles publiés en ligne correspondent aux sujets que vous indiquez.

Exemples d'utilisation des Alertes Google :

- suivre l'évolution d'une affaire ;
- obtenir des informations à jour sur un concurrent ou un secteur d'activités ;
- connaître l'actualité d'une personnalité ;
- suivre les résultats d'une équipe sportive.

Créez une alerte à l'aide du formulaire situé sur votre droite.

Vous pouvez également vous [connecter pour gérer vos alertes](#)

### Créer une Alerte Google

Entrez le sujet sur lequel vous souhaitez obtenir des informations.

Termes recherchés:

Type:

Fréquence:

Email:

Google s'engage à ne pas vendre et à ne pas communiquer votre adresse de messagerie.

© 2007 Google · [Accueil Google](#) · [Aide Google Alerts](#) · [Conditions d'utilisation](#) · [Règles de confidentialité](#)



MATHÉMATIQUES APPLIQUÉES - INFORMATIQUE

# Google Alerts, mais aussi Google Mail

Gmail [Calendar](#) [Documents](#) [Photos](#) [Reader](#) [Web](#) [more ▾](#)

████████@gmail.com | [Settings](#) | [Older version](#) | [Help](#) | [Sign out](#)



[Show search options](#)  
[Create a filter](#)

## Compose Mail

### Inbox

[Starred](#)

[Chats](#)

[Sent Mail](#)

[Drafts](#)

[All Mail](#)

[Spam \(360\)](#)

[Trash](#)

[Contacts](#)

•

- Labels [Edit labels](#)

- Invite a friend

Give Gmail to:

98 left

[Preview Invite](#)

« [Back to Inbox](#) [Archive](#) [Report spam](#) [Delete](#) [Move to ▾](#) [Labels ▾](#) [More actions ▾](#) 1 of 18 [Older >](#)

**Carrière de Carlita** [New](#) [X](#)

★ **Nicolas S.** to me [show details](#) 11:10 AM (0 minutes ago) [Reply ▾](#)

Salut Jacques,

Tu avances sur la promo du dernier CD de Carla ? On compte tous sur toi. Tu conserves toute ma confiance.

Nico.

[Reply](#) [Forward](#)

[Sponsored Links \[Feedback\]\(#\)](#)

[\\$99 Luxury Watches](#)  
High Quality Guarantee  
Christmas sales promotion, Buy Now  
HandMadeRolex.com

[Manufacture Firenze straps](#)  
Top quality leather watch straps &  
accessories fully Italian handmade  
www.manufacturefirenze.it

[Replica Panerai Watches](#)  
Sale Replicas Panerai - Breitling  
IWC, Chopard, Hublot, Montblanc  
www.watch88.com/Panerai-Montres

[Luxury Watches For Cheap](#)  
5000+ Styles For Luxury Watches  
120% Low Prices. Free Shipping  
www.Rolex2u.com

[Luxury Watches \(€87/\\$130\)](#)  
UK & USA Based! Beautiful Watches,  
All With Money Back Guarantee.  
www.thewatchdome.com

[About these links](#)

« [Back to Inbox](#) [Archive](#) [Report spam](#) [Delete](#) [Move to ▾](#) [Labels ▾](#) [More actions ▾](#) 1 of 18 [Older >](#)



MACHINISTES APPLIQUÉS - INFORMATIQUE



# Filtre à mot-clés secrets (*Private Searching*)

## Définition plus technique

Trois algorithmes :

- `QueryConstruction` : génère une requête  $Q$  à partir d'un ensemble de mots-clés.



# Filtre à mot-clés secrets (*Private Searching*)

## Définition plus technique

Trois algorithmes :

- `QueryConstruction` : génère une requête  $Q$  à partir d'un ensemble de mots-clés.
- `StreamSearch` : génère une réponse à partir de  $Q$  et des documents du flux.



# Filtre à mot-clés secrets (*Private Searching*)

## Définition plus technique

Trois algorithmes :

- `QueryConstruction` : génère une requête  $Q$  à partir d'un ensemble de mots-clés.
- `StreamSearch` : génère une réponse à partir de  $Q$  et des documents du flux.
- `FileReconstruction` : déchiffre la réponse pour produire les documents correspondant à la requête.



# Plan

- 1 Problématique
  - Filtre à mot-clés
  - Exemple : Google Alerts
- 2 Du PIR au Private Searching
  - Retrait d'information privé (PIR)
  - Passage au filtre par mot-clés
- 3 Notre solution
  - Principe
  - Détails du chiffrement utilisé
  - Performances
- 4 Conclusion



# Définition

## 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.



# Définition

## 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.

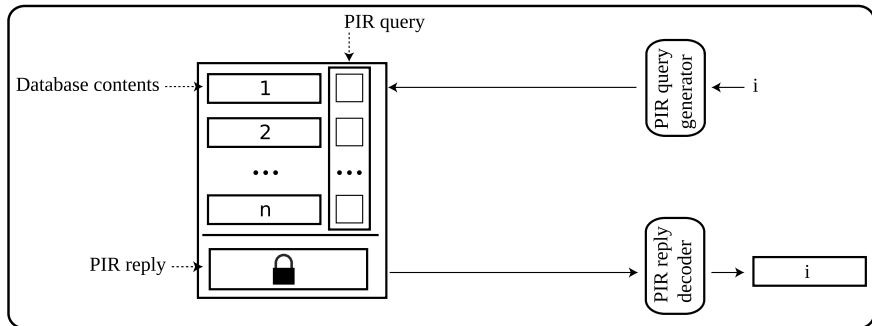
## Un peu plus formelle

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 indistinguables de celles correspondant à  $e_2$ .



# Protocole PIR



# 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 :  $F_{RIP}^d$ .

# Chiffrement homomorphe

## Définition

$$D(E(m_1) \oplus E(m_2)) = m_1 \otimes m_2$$

où  $\oplus$  et  $\otimes$  désignent des opérations de groupe.



# Chiffrement homomorphe

## Définition

$$D(E(m_1) \oplus E(m_2)) = m_1 \otimes m_2$$

où  $\oplus$  et  $\otimes$  désignent des opérations de groupe.

## Exemple : Paillier

- Clef publique :  $n = pq$  entier RSA avec  $p < q$ ,  $p \nmid q - 1$ .
- Chiffrement :  $(m, r) \in \mathbb{Z}/n\mathbb{Z} \times (\mathbb{Z}/n\mathbb{Z})^* \mapsto c = (1 + n)^m r^n \bmod n^2$ .
- Déchiffrement :  $c = r^n \bmod n$  donne  $r$ .
- Homomorphisme :

$$D(E(m_1) \times E(m_2)) = m_1 + m_2$$

# Paillier

## Keygen

```
def keygen(ks):
    todo = True
    while todo:
        p = random_prime(1 << ks)
        q = random_prime(1 << ks)
        if p > q:
            t = p
            p = q
            q = t
        if (q - 1) % p != 0:
            todo = False
    return (p, q, p * q)
```



# Paillier

## Encryption

```
def encrypt(m, n):  
    r = randint(0, n - 1)  
    while gcd(r, n) == 0:  
        r = randint(0, n - 1)  
    s = n * n  
    u = Mod(1 + n, s)  
    u = u^m  
    r = Mod(r, s)  
    r = r^n  
    return u * r
```



# Paillier

## Decryption

```
def decrypt(c, n, p):  
    u = Mod(c, n)  
    s = n * n  
    phi = (p - 1) * (n/p - 1)  
    e = Mod(n, phi)  
    d = 1 / e  
    r = u^d  
    v = Mod(r, s) ^ n  
    t = Mod(c, s) / v  
    return int(t - 1) / n
```



# Paillier

## Usage

```
sage : (p, q, n) = keygen(20)
```

# Paillier

## Usage

```
sage : (p, q, n) = keygen(20)
sage : (p, q, n)
(192557, 720089, 138658177573)
```

# Paillier

## Usage

```
sage : (p, q, n) = keygen(20)
sage : (p, q, n)
(192557, 720089, 138658177573)
sage : c1 = encrypt(1, n)
sage : c2 = encrypt(1, n)
```

# Paillier

## Usage

```
sage : (p, q, n) = keygen(20)
sage : (p, q, n)
(192557, 720089, 138658177573)
sage : c1 = encrypt(1, n)
sage : c2 = encrypt(1, n)
sage : c1
16768997473026340839836
sage : c2
14672963152557506378498
```

# Paillier

## Usage

```
sage : (p, q, n) = keygen(20)
sage : (p, q, n)
(192557, 720089, 138658177573)
sage : c1 = encrypt(1, n)
sage : c2 = encrypt(1, n)
sage : c1
16768997473026340839836
sage : c2
14672963152557506378498
sage : decrypt(c1, n, p)
1
```

# Paillier

## Usage

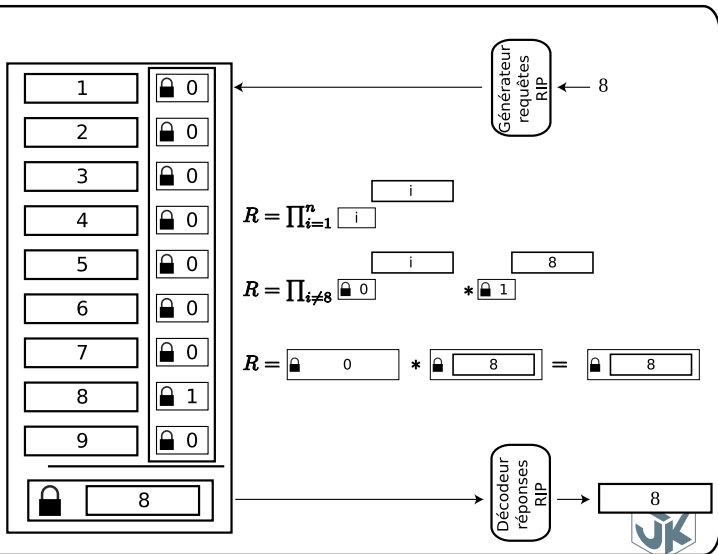
```
sage : (p, q, n) = keygen(20)
sage : (p, q, n)
(192557, 720089, 138658177573)
sage : c1 = encrypt(1, n)
sage : c2 = encrypt(1, n)
sage : c1
16768997473026340839836
sage : c2
14672963152557506378498
sage : decrypt(c1, n, p)
1
sage : decrypt(c1 * c2, n, p)
2
```

# Paillier

## Usage

```
sage : (p, q, n) = keygen(20)
sage : (p, q, n)
(192557, 720089, 138658177573)
sage : c1 = encrypt(1, n)
sage : c2 = encrypt(1, n)
sage : c1
16768997473026340839836
sage : c2
14672963152557506378498
sage : decrypt(c1, n, p)
1
sage : decrypt(c1 * c2, n, p)
2
sage : decrypt(encrypt(6, n)^7, n, p)
42
```

# Protocole PIR par chiffrement homomorphe



# Plan

- 1 Problématique
  - Filtre à mot-clés
  - Exemple : Google Alerts
- 2 Du PIR au Private Searching
  - Retrait d'information privé (PIR)
  - Passage au filtre par mot-clés
- 3 Notre solution
  - Principe
  - Détails du chiffrement utilisé
  - Performances
- 4 Conclusion



# Du PIR au PS

	PIR	PS
Requête	indice de la base	ensemble de mots-clés
Base de données	Ensemble figé de documents	Flux de documents
Réponse	Immédiate	Périodique



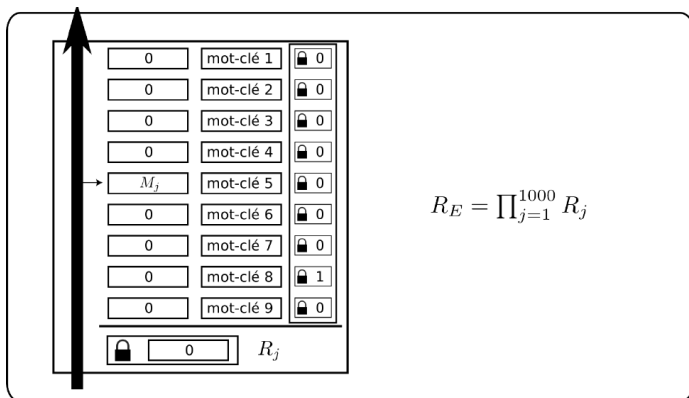
# Du PIR au PS

## Solution

- Liste de mots-clés admissibles  $W = \{w_1, \dots, w_{|W|}\}$ .
- Requête  $R$  code les indices des mots-clés recherchés.
- Chaque document du flux devient une BD virtuelle de taille  $|W|$ .
- La requête PS est appliquée comme requête PIR sur cette BD.
- Un document du flux  $\rightarrow$  une réponse PIR.
- Comment stocker ces réponses PIR ?



# Du PIR au PS



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



# Stratégies d'accumulation

## Ostrovsky et Skeith

- On récupère au plus  $m$  documents ;
- Réponse PS = buffer de  $2\gamma m$  réponses PIR ;
- Une réponse PIR est stockée au hasard dans  $\gamma$  positions ;
- Collision  $\rightarrow$  emplacement perdu.



# Stratégies d'accumulation

## Ostrovsky et Skeith

- On récupère au plus  $m$  documents ;
- Réponse PS = buffer de  $2\gamma m$  réponses PIR ;
- Une réponse PIR est stockée au hasard dans  $\gamma$  positions ;
- Collision  $\rightarrow$  emplacement perdu.

## Bethencourt et al.

- Plusieurs buffers (données et méta-données) ;
- Réponse PS = buffer de réponses PIR ;
- Réponse PIR copiée dans la moitié des positions en moyenne ;
- Filtre de Bloom pour le nombre de matchs du  $j$ -ème document ;

# Stratégies d'accumulation


## Ostrovsky et Skeith

- On récupère au plus  $m$  documents ;
- Réponse PS = buffer de  $2\gamma m$  réponses PIR ;
- Une réponse PIR est stockée au hasard dans  $\gamma$  positions ;
- Collision  $\rightarrow$  emplacement perdu.


## Bethencourt et al.

- Plusieurs buffers (données et méta-données) ;
- Réponse PS = buffer de réponses PIR ;
- Réponse PIR copiée dans la moitié des positions en moyenne ;
- Filtre de Bloom pour le nombre de matchs du  $j$ -ème document ;
- Besoin de pouvoir accumuler les résultats.

# Accumulation des résultats



# Accumulation des résultats



# Plan

- 1 Problématique
  - Filtre à mot-clés
  - Exemple : Google Alerts
- 2 Du PIR au Private Searching
  - Retrait d'information privé (PIR)
  - Passage au filtre par mot-clés
- 3 Notre solution
  - Principe
  - Détails du chiffrement utilisé
  - Performances
- 4 Conclusion



# Principe

- Bethencourt et al. améliore Ostrovsky et Skeith III par l'utilisation de filtres de Bloom ;



# Principe

- Bethencourt et al. améliore Ostrovsky et Skeith III par l'utilisation de filtres de Bloom ;
- Le chiffrement d'Aguilar et Gaborit est plusieurs fois homomorphe ;

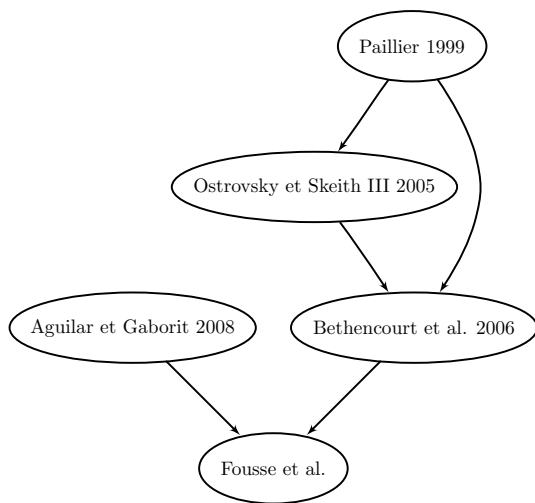


# Principe


- Bethencourt et al. améliore Ostrovsky et Skeith III par l'utilisation de filtres de Bloom ;
- Le chiffrement d'Aguilar et Gaborit est plusieurs fois homomorphe ;
- $\Rightarrow$  utiliser le chiffrement par le bruit à la place de Paillier dans le logiciel de Bethencourt et al ;
- et ajouter la récursion.



# Vue d'ensemble



# Ostrovsky et Skeith III CRYPTO'05



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

## Performances

- Les éléments à zéro n'engendrent pas un coût calculatoire.
- Requêtes grandes mais changent peu souvent.

# *New Techniques for Private Stream Searching* (Bethencourt et al. 2006)

## QueryConstruction

- Les éléments  $Q_i$  de la requête sont des chiffrés de 0 ou de 1.



# New Techniques for Private Stream Searching (Bethencourt et al. 2006)

## StreamSearch

Pour le document  $f_i$  du flux :

- $n_i = \#$ mots-clefs correspondant à la requête.
- $c_i = E(n_i)$ .
- 3 filtres de Bloom  $F$ ,  $C$  et  $I$  :
  - $F$  contient les données ( $F_j = E(\sum_{g(i,j)=1} c_i f_i)$ ).
  - $C$  contient le nombre de mots-clefs matchant par document du flux ( $C_j = E(\sum_{g(i,j)=1} c_i)$ ).
  - $I$  code les indices des fichiers correspondant à au moins un mot-clef.



# New Techniques for Private Stream Searching (Bethencourt et al. 2006)

## FileReconstruction

- Déchiffrement des buffers ;
- Calcul des indices matchants potentiels (avec  $l$ ) ;
- Résolution d'un système linéaire pour retrouver  $n_i$ .



# Problèmes avec Paillier

$$E(m_1) \times E(m_2) \simeq E(m_1 + m_2)$$



# Problèmes avec Paillier

$$\begin{aligned} E(m_1) \times E(m_2) &\simeq E(m_1 + m_2) \\ E(E(m_1)) \times E(E(m_2)) &\simeq E(E(m_1) + E(m_2)) \simeq ? \end{aligned}$$



# Problèmes avec Paillier

$$\begin{aligned}E(m_1) \times E(m_2) &\simeq E(m_1 + m_2) \\E(E(m_1)) \times E(E(m_2)) &\simeq E(E(m_1) + E(m_2)) \simeq ? \\E(E(m_1)) + E(E(m_2)) &\simeq ?\end{aligned}$$



# Problèmes avec Paillier

$$\begin{aligned}E(m_1) \times E(m_2) &\simeq E(m_1 + m_2) \\E(E(m_1)) \times E(E(m_2)) &\simeq E(E(m_1) + E(m_2)) \simeq ? \\E(E(m_1)) + E(E(m_2)) &\simeq ?\end{aligned}$$

Un protocole de filtre basé sur Paillier ne permet pas la récursion :

- Requête linéaire en la taille du dictionnaire ;
- $W$  petit : beaucoup de collisions ;
- $W$  grand : plus de calculs et plus grande requête.

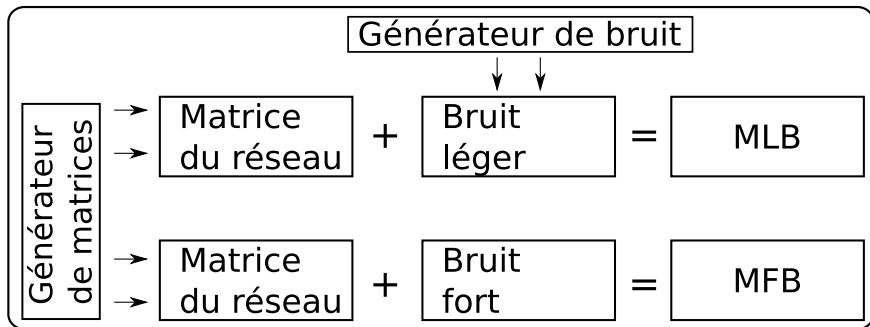


# Plan

- 1 Problématique
  - Filtre à mot-clés
  - Exemple : Google Alerts
- 2 Du PIR au Private Searching
  - Retrait d'information privé (PIR)
  - Passage au filtre par mot-clés
- 3 Notre solution
  - Principe
  - **Détails du chiffrement utilisé**
  - Performances
- 4 Conclusion



# Aguilar et Gaborit WeWORC'07, ISIT'08



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, ISIT'08

$$\begin{array}{l}
 e_{1,1} * \\
 e_{1,2} * \\
 e_{1,3} *
 \end{array}
 \left( \begin{array}{c} \boxed{\text{BASE 1}} \end{array} + \begin{array}{c} \begin{array}{cccccc} +1 & -1 & +1 & 0 & 0 & 0 \\ +1 & +1 & -1 & 0 & 0 & 0 \\ -1 & +1 & +1 & 0 & 0 & 0 \end{array} \end{array} \right) \triangle$$

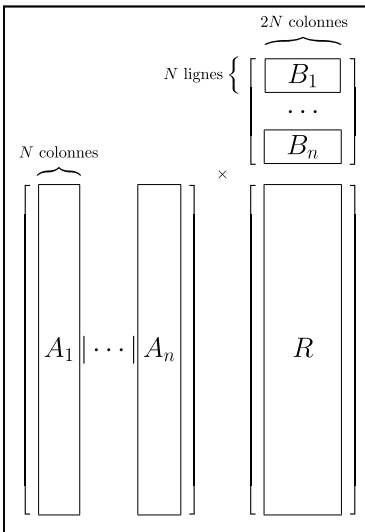
$$\begin{array}{l}
 e_{2,1} * \\
 e_{2,2} * \\
 e_{2,3} *
 \end{array}
 \left( \begin{array}{c} \boxed{\text{BASE 2}} \end{array} + \begin{array}{c} \begin{array}{cccccc} +64 & +1 & -1 & 0 & 0 & 0 \\ -1 & +64 & -1 & 0 & 0 & 0 \\ +1 & +1 & +64 & 0 & 0 & 0 \end{array} \end{array} \right) \triangle$$

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, ISIT'08

## Génération de la réponse



- La base de données est représentée comme une matrice.
  - Un élément  $\rightarrow$  un bloc  $A_i$  de  $N$  colonnes.
- Les matrices de la requête sont concaténées.
  - Un élément  $\rightarrow$  un bloc  $B_i$  de  $N$  lignes et  $2N$  colonnes.
- On réalise une multiplication par blocs.

## Coût

- Chaque scalaire de  $A$  multiplie une ligne d'une matrice de la requête.
- $N = 50 \Rightarrow$  coût par bit : 100 sommes de 64 bits.

# Principe

Détails du chiffrement :

$$M = [M_1 | M_2], \quad M_1 \text{ inversible } (N \times 2N)$$



# Principe

Détails du chiffrement :

$$M = [M_1 | M_2], \quad M_1 \text{ inversible } (N \times 2N)$$

$$P_i : \text{ inversible, } (N \times N)$$



# Principe

Détails du chiffrement :

$$M = [M_1 | M_2], \quad M_1 \text{ inversible } (N \times 2N)$$

$$P_i : \text{ inversible, } (N \times N)$$

$$\Delta : \text{ inversible, } (2N \times 2N)$$



# Principe

Détails du chiffrement :

$$M = [M_1 | M_2], \quad M_1 \text{ inversible } (N \times 2N)$$

$$P_i : \text{ inversible, } (N \times N)$$

$$\Delta : \text{ inversible, } (2N \times 2N)$$

$$B_i = [P_i M_1 | P_i M_2 + D_i] \Delta, \quad D_i \text{ bruit faible } \pm 1$$



# Principe

Détails du chiffrement :

$$M = [M_1 | M_2], \quad M_1 \text{ inversible } (N \times 2N)$$

$$P_i : \text{ inversible, } (N \times N)$$

$$\Delta : \text{ inversible, } (2N \times 2N)$$

$$B_i = [P_i M_1 | P_i M_2 + D_i] \Delta, \quad D_i \text{ bruit faible } \pm 1$$

$$B_j = [P_j M_1 | P_j M_2 + D_j] \Delta, \quad D_j \text{ bruit fort}$$



# Principe

Détails du chiffrement :

$$M = [M_1 | M_2], \quad M_1 \text{ inversible } (N \times 2N)$$

$$P_i : \text{ inversible, } (N \times N)$$

$$\Delta : \text{ inversible, } (2N \times 2N)$$

$$B_i = [P_i M_1 | P_i M_2 + D_i] \Delta, \quad D_i \text{ bruit faible } \pm 1$$

$$B_j = [P_j M_1 | P_j M_2 + D_j] \Delta, \quad D_j \text{ bruit fort}$$

$$R = \sum A_i B_i$$

$$= \sum_{\text{soft}} [A_i P_i M_1 | A_i P_i M_2 + A_i D_i] \Delta + \sum_{\text{hard}} [A_j P_j M_1 | A_j P_j M_2 + A_j D_j] \Delta.$$



# Principe

On récupère

$$R' = \sum_{\text{soft}} A_i D_i + \sum_{\text{hard}} A_j D_j$$



# Principe

On récupère

$$\begin{aligned} R' &= \sum_{\text{soft}} A_i D_i + \sum_{\text{hard}} A_j D_j \\ &= q \sum_{\text{hard}} A_j + \text{noise} \end{aligned}$$



# Exemple (1/3)

## Génération de la requête

Matrices 2x4

GF(521)

Clef privé :  $M_1, M_2, \Delta$

Contenu de la requête :  $B_1, B_2, 521, 3$

Bruit léger  $\{-1, +1\}$

Bruit fort  $\{+64, -64\}$

$$\begin{aligned}
 M_1 &= \begin{pmatrix} 255 & 323 \\ 133 & 449 \end{pmatrix} \\
 M_2 &= \begin{pmatrix} 269 & 469 \\ 159 & 58 \end{pmatrix} \\
 M &= \begin{pmatrix} 255 & 323 & 269 & 469 \\ 133 & 449 & 159 & 58 \end{pmatrix} \\
 \Delta &= \begin{pmatrix} 517 & 411 & 328 & 340 \\ 269 & 172 & 35 & 467 \\ 474 & 7 & 136 & 496 \\ 89 & 233 & 197 & 403 \end{pmatrix}
 \end{aligned}$$

$$\begin{aligned}
 P_1 &= \begin{pmatrix} 285 & 115 \\ 322 & 3 \end{pmatrix} \\
 P_2 &= \begin{pmatrix} 259 & 326 \\ 38 & 232 \end{pmatrix} \\
 D_1 &= \begin{pmatrix} 1 & 0 \\ 1 & 520 \end{pmatrix} \\
 D_2 &= \begin{pmatrix} 64 & 520 \\ 1 & 64 \end{pmatrix} \\
 B_1 &= \begin{pmatrix} 7 & 313 & 77 & 60 \\ 36 & 356 & 65 & 518 \end{pmatrix} \\
 B_2 &= \begin{pmatrix} 365 & 204 & 137 & 71 \\ 262 & 297 & 91 & 490 \end{pmatrix}
 \end{aligned}$$



# Exemple (2/3)

## Génération de la réponse

- Couper les éléments en morceaux de 3 bits
- Multiplier la matrice données avec la matrice requête

$$A_1 = \begin{pmatrix} 3 & 7 \end{pmatrix}$$

$$A_2 = \begin{pmatrix} 5 & 2 \end{pmatrix}$$

$$R = \begin{pmatrix} 17 & 356 & 511 & 452 \end{pmatrix}$$



## Exemple (3/3)

### Décodage de la réponse

- |                                    |                          |
|------------------------------------|--------------------------|
| 1 - Permuter                       | 4 - Déamplifier le bruit |
| 2 - Récupérer le vecteur du réseau | 5 - Filtrer le bruit     |
| 3 - Récupérer le bruit             | 6 - Reconstruire         |

### Exemple

$$R\Delta^{-1} = ( 360 \quad 243 \quad 248 \quad 490 )$$

# Exemple (3/3)

## Décodage de la réponse

- |                                    |                          |
|------------------------------------|--------------------------|
| 1 - Permuter                       | 4 - Déamplifier le bruit |
| 2 - Récupérer le vecteur du réseau | 5 - Filtrer le bruit     |
| 3 - Récupérer le bruit             | 6 - Reconstruire         |

## Exemple

$$\begin{aligned}
 R\Delta^{-1} &= \begin{pmatrix} 360 & 243 & 248 & 490 \end{pmatrix} \\
 R'_1 &= \begin{pmatrix} 360 & 243 \end{pmatrix} \\
 R'_2 &= \begin{pmatrix} 248 & 490 \end{pmatrix} \\
 R'_2 - R'_1 M_1^{-1} M_2 &= \begin{pmatrix} 332 & 116 \end{pmatrix} \\
 332 &= 5 \cdot 64 + 12 \\
 116 &= 2 \cdot 64 - 12
 \end{aligned}$$

# Intérêt du chiffrement utilisé

Le chiffrement transforme une addition en une addition :

$$\begin{aligned} \text{PIR}(A_1, A_2, \dots, A_n, B_1, B_2, \dots, B_n) &= \text{PIR}(\mathbf{A}, \mathbf{B}) \\ \text{PIR}(\mathbf{A}_1, \mathbf{B}) + \text{PIR}(\mathbf{A}_2, \mathbf{B}) &\simeq \text{PIR}(\mathbf{A}_1 + \mathbf{A}_2, \mathbf{B}) \\ \text{PIR}(\mathbf{A}'_1, \mathbf{B}) + \text{PIR}(\mathbf{A}'_2, \mathbf{B}) &\simeq \text{PIR}(\mathbf{A}'_1 + \mathbf{A}'_2, \mathbf{B}) \end{aligned}$$



# Intérêt du chiffrement utilisé

Le chiffrement transforme une addition en une addition :

$$\begin{aligned} \text{PIR}(A_1, A_2, \dots, A_n, B_1, B_2, \dots, B_n) &= \text{PIR}(\mathbf{A}, \mathbf{B}) \\ \text{PIR}(\mathbf{A}_1, \mathbf{B}) + \text{PIR}(\mathbf{A}_2, \mathbf{B}) &\simeq \text{PIR}(\mathbf{A}_1 + \mathbf{A}_2, \mathbf{B}) \\ \text{PIR}(\mathbf{A}'_1, \mathbf{B}) + \text{PIR}(\mathbf{A}'_2, \mathbf{B}) &\simeq \text{PIR}(\mathbf{A}'_1 + \mathbf{A}'_2, \mathbf{B}) \end{aligned}$$

Récursion en dimension 2 :

$$\begin{aligned} &\text{PIR}(\text{PIR}(\mathbf{A}_1, \mathbf{B}_1), \text{PIR}(\mathbf{A}_2, \mathbf{B}_1), \dots, \text{PIR}(\mathbf{A}_n, \mathbf{B}_1), \mathbf{B}_2) + \\ &\text{PIR}(\text{PIR}(\mathbf{A}'_1, \mathbf{B}_1), \text{PIR}(\mathbf{A}'_2, \mathbf{B}_1), \dots, \text{PIR}(\mathbf{A}'_n, \mathbf{B}_1), \mathbf{B}_2) \simeq \\ &\text{PIR}(\text{PIR}(\mathbf{A}_1 + \mathbf{A}'_1, \mathbf{B}_1), \text{PIR}(\mathbf{A}_2 + \mathbf{A}'_2, \mathbf{B}_1), \dots, \text{PIR}(\mathbf{A}_n + \mathbf{A}'_n, \mathbf{B}_1), \mathbf{B}_2) \end{aligned}$$



# Paramètres du protocole

## Paramètres du chiffrement

- Taille  $l_0$  des entiers de  $\mathbf{A}$ .
- Dimensions  $L$  et  $N$  des matrices ;
- Taille du premier  $p$  ;
- Taille des textes clairs ;
- Facteur d'expansion.

## Paramètres globaux

- Tailles des buffers  $F$ ,  $I$  et  $C$  ;
- Paramètre de correction  $\epsilon$  ;
- Nombre de mot-clés de la requête ;
- Nombre moyen de mot-clés présents dans un document ;
- Nombre moyen de mot-clés de la requête présents dans un document ;
- Nombre de documents du flux traités.

# Contraintes

## Hypothèses

- Un emplacement du buffer accumulera en moyenne la moitié des  $t$  messages du flux traités ;
- Un message donné correspond à la requête avec une probabilité bornée ;
- Les matrices  $A$  contiennent des entiers sur  $l_0$  bits ;
- Le nombre de mot-clés présents dans chaque document est borné.



# Contraintes

## Bornes

(Rappel) On récupère

$$R' = \sum_{soft} A_i D_i + \sum_{hard} A_j D_j$$

# Contraintes

## Bornes

(Rappel) On récupère

$$\begin{aligned} R' &= \sum_{\text{soft}} A_i D_i + \sum_{\text{hard}} A_j D_j \\ &= q \sum_{\text{hard}} A_j + \text{noise} \end{aligned}$$

# Contraintes

## Bornes

(Rappel) On récupère

$$\begin{aligned} R' &= \sum_{\text{soft}} A_i D_i + \sum_{\text{hard}} A_j D_j \\ &= q \sum_{\text{hard}} A_j + \text{noise} \end{aligned}$$

Borne sur le bruit :

$$\text{noise} \leq |a_{ij}| (m(N-1) + \hat{m}N)$$

# Contraintes

## Bornes

(**Rappel**) On récupère

$$\begin{aligned}
 R' &= \sum_{soft} A_i D_i + \sum_{hard} A_j D_j \\
 &= q \sum_{hard} A_j + noise
 \end{aligned}$$

Borne sur le bruit :

$$noise \leq |a_{ij}| (m(N-1) + \hat{m}N)$$

Borne sur le signal :

$$data \leq q|a_{ij}|m$$

où  $m$  désigne le nombre total, pour l'emplacement considéré, des mot-clés trouvés dans les documents traités ( $m + \hat{m}$  le nombre total de mot-clés présents dans les documents).

# Contraintes

## Bornes

- Le bruit ne doit pas déborder dans le signal :

$$q > 2^b N(m + \hat{m}) \quad (1)$$

- Le signal ne doit pas déborder mod  $p$  :

$$p > q2^b m \quad (2)$$



# Contraintes

## Bornes

- Le bruit ne doit pas déborder dans le signal :

$$q > 2^b N(m + \hat{m}) \quad (1)$$

- Le signal ne doit pas déborder mod  $p$  :

$$p > q2^b m \quad (2)$$

- On peut supposer que le facteur d'expansion des entiers est 3.



# Analyse de la récursion

Avec une récursion d'ordre  $d$  ( $|W| = n^d$ ) :

## Communication Client vers Serveur

- Coût  $n^d$  sans récursion.
- Coût  $n + 3n + 9n + \dots + 3^{d-1}n$  avec récursion.
- $\Rightarrow$  facteur  $\frac{3}{2} \left(\frac{3}{n}\right)^{d-1}$  (meilleur avec récursion !)



# Analyse de la récursion

Avec une récursion d'ordre  $d$  ( $|W| = n^d$ ) :

## Communication Client vers Serveur

- Coût  $n^d$  sans récursion.
- Coût  $n + 3n + 9n + \dots + 3^{d-1}n$  avec récursion.
- $\Rightarrow$  facteur  $\frac{3}{2} \left(\frac{3}{n}\right)^{d-1}$  (meilleur avec récursion !)

## Coût de calcul du serveur

- Même analyse que pour la taille de la requête ?



# Analyse de la récursion

Avec une récursion d'ordre  $d$  ( $|W| = n^d$ ) :

## Communication Client vers Serveur

- Coût  $n^d$  sans récursion.
- Coût  $n + 3n + 9n + \dots + 3^{d-1}n$  avec récursion.
- $\Rightarrow$  facteur  $\frac{3}{2} \left(\frac{3}{n}\right)^{d-1}$  (meilleur avec récursion !)

## Coût de calcul du serveur

- Même analyse que pour la taille de la requête ?
- Mais un mot-clé non présent n'entraîne pas de coût de calcul !

## Taille de la réponse


- Expansion  $6^d$ , trop cher ?
- On peut diminuer le nombre de buffers.

# Plan

- 1 Problématique
  - Filtre à mot-clés
  - Exemple : Google Alerts
- 2 Du PIR au Private Searching
  - Retrait d'information privé (PIR)
  - Passage au filtre par mot-clés
- 3 Notre solution
  - Principe
  - Détails du chiffrement utilisé
  - **Performances**
- 4 Conclusion



# Vitesse en ko/s, taille des fichiers en ko



# Temps

$$|I| = 315$$

$$|C| = 135$$

$$|F| = 512$$

	Réseaux	Paillier
QueryConstruction	20s	3s
FileReconstruction	44s	36s



# Conclusion

- Avec le chiffrement basé sur les réseaux, la récursion est possible pour le *private searching* ;
- Déjà plus performant malgré un code non optimisé



# Conclusion

- Avec le chiffrement basé sur les réseaux, la récursion est possible pour le *private searching* ;
- Déjà plus performant malgré un code non optimisé (et même grossièrement non optimisé).



# Perspectives

- Implémenter la récursion ;
- Utiliser LinBox au lieu de NTL ;
- Trouver automatiquement les bons paramètres et mieux comparer ;
- Trouver l'Application-qui-tue (*killer app*) qui montre qu'on est bien meilleur que les autres ;
- Application au serveur de mail anonyme (cf. *Pynchon Gate*).

