

# Amélioration de la complexité de résolution du problème de décodage par syndrome en métrique rang

Philippe Gaborit<sup>1</sup>   Olivier Ruatta<sup>1</sup>   **Julien Schrek**<sup>1</sup>

<sup>1</sup>Université de Limoges, XLIM-DMI

8 Octobre 2012

# Plan

- 1 Problème de décodage par syndrome
- 2 Problème de décodage par syndrome en métrique rang
- 3 Attaque sur le support
- 4 Attaque par les  $q$ -polynômes
- 5 Application à la cryptanalyse

# Codage et Cryptographie

## La cryptographie à besoin de problèmes difficiles.

- factorisation
- logarithme discret
- problème SVP dans les réseaux
- problème de décodage par syndrome

En code et cryptographie, la sécurité des cryptosystèmes est liée au problème de décodage par syndrome.

# Problème de décodage par syndrome

## Syndrome decoding

*Trouver  $x$  de petit poids tel que  $Hx^t = y$  avec  $H$  une matrice aléatoire connue et  $y$  un vecteur connu.*

Les cryptosystèmes qui utilisent les codes correcteurs basent leur sécurité sur ce problème :

- chiffrement de McEliece/Niederreiter
- signature CFS
- authentification basé sur le protocole de Stern

# Problème de décodage par syndrome

Problème étudié depuis des dizaines d'années en théorie des codes.

## Caractéristiques :

- NP-Complet
- Est basé sur des opérations rapides
- A priori résistant à l'ordinateur quantique

Meilleures attaques connues : Information Set Decoding et

variations : FS '09, MMT '11, BJMT '12

Les attaques semblent converger, ce qui semble aller vers une stabilisation de la difficulté du problème.

## Métrique rang : notations

La métrique rang se définit dans le cadre des extensions de corps finis.

- $\mathbb{F}_q$  un corps fini avec  $q$  une puissance de nombre premier.
- $\mathbb{F}_{q^m}$  une extension de corps de degré  $m$  de  $\mathbb{F}_q$ .

$\mathbb{F}_{q^m}$  **peut être vu comme un espace vectoriel sur  $\mathbb{F}_q$ .**

- $\mathcal{C}$  un code linéaire sur  $\mathbb{F}_{q^m}$  de dimension  $k$  et de longueur  $n$ .
- $G$  la matrice génératrice  $k \times n$  du code  $\mathcal{C}$ .
- $H$  la matrice  $n \times (n - k)$  de contrôle de  $\mathcal{C}$ ,  $GH = 0$ .

## Métrique rang

Les mots du code  $\mathcal{C}$  sont des  $n$ -uplets dont les coordonnées appartiennent à  $\mathbb{F}_{q^m}$ .

$$v = (v_1, \dots, v_n)$$

avec  $v_i \in \mathbb{F}_{q^m}$ .

Chacunes de ces coordonnées  $v_i$  est un vecteur à coordonnées dans  $\mathbb{F}_q$ .

### Métrique rang

*Dire que  $v$  est de rang  $r$  signifie que les  $v_i$  engendrent un sous e.v. de  $\mathbb{F}_{q^m}$  de dimension  $r$ .*

# Problème de décodage par syndrome en métrique rang

L'énoncé du problème reste le même en métrique rang.

## Syndrome decoding

*Trouver  $e$  de petit poids tel que  $He^t = y$  avec  $H$  une matrice aléatoire connue et  $y$  un vecteur connu.*

- induit de petites tailles de clés
- pas prouvé NP-Complet

# Métrique rang et cryptographie

**On peut définir le même type d'algorithmes cryptographiques que pour la métrique de Hamming :**

- cryptosystème GPT '91 : analogue de McEliece
- authentification (et signature) par zero-knowledge : Chen '95 (cassé), Gaborit-Schrek-Zemor '11

## Complexité des attaques connues

Complexité des attaques de A.Ourivski et T.Johansson '02 :

- énumération des bases :  $\leq (k+r)^3 q^{(r-1)(m-r)+2}$   
(amélioration sur la partie polynomiale de Chabaud-Stern '96)
- énumération des coordonnées :  $\leq (k+r)^3 r^3 q^{(r-1)(k+1)}$

$\Rightarrow$  **Ces attaques ne dépendent pas de  $n$ .**

# Analogie sur le support entre métriques Hamming et Rang

- Support d'un mot d'un code sur  $\mathbb{F}_{q^m}$

Le support d'un mot  $x = (x_1, x_2, \dots, x_n)$  est l'ensemble des positions  $x_i \neq 0$

**Comment retrouver un mot de petit poids associé à un syndrome ?**

- 1) trouver le support du mot (ou plutôt essayer de deviner le support)
- 2) résoudre un système pour retrouver le mot exact pour un support donné

- Support d'un mot en métrique rang

Le support d'un mot  $x = (x_1, x_2, \dots, x_n)$  de rang  $r$  est l'espace vectoriel  $E$  de dim  $r$  tel que  $\forall x_i, x_i \in E$ .

**Comment retrouver un mot associé à un syndrome donné ?**

- 1) trouver le support (ou plutôt essayer de deviner le support)
- 2) résoudre un système à partir des équations du syndrome la valeur exacte des  $x_i \in E$

Remarque : à la différence du support en métrique de Hamming, en général pour la métrique rang :  $x_i \neq 0$ .

# Attaque sur le support : analogie sur les attaques Hamming/Rang

- Attaque en métrique de Hamming pour retrouver le support
    - une approche consisterait à essayer TOUS les supports : tous les ensembles de positions de poids  $w$
- ⇒ Bien sûr on ne fait jamais ca!!!!

- Attaque en métrique rang pour retrouver le support

L'analogie de cette attaque en métrique rang : essayer tous les supports possibles, ie tous les espaces vectoriels de dimension  $r$ , puis résoudre un système.

⇒ c'est l'attaque de Chabaud-Stern ('96) - améliorée par OJ '02

Par analogie avec le cas Hamming : on voit bien que ce n'est pas optimal!!!! En particulier la complexité de l'exposant ne dépend pas de  $n$ !

# Amélioration : ISD pour métrique rang

- Information Set Decoding en métrique de Hamming (version simple)
  - taille du syndrome :  $n - k \rightarrow n - k$  équations
  - on prend au hasard  $n - k$  colonnes, si elles contiennent le support de l'erreur, on peut résoudre
- Analogie en métrique rang :
  - taille du syndrome :  $n - k \rightarrow (n - k)m$  équations sur  $\mathbb{F}_q$
  - on prend au hasard un sur-espace  $E'$  de  $E$  de dimension  $r'$ 
    - $\rightarrow$  on peut résoudre si  $nr' \leq (n - k)m$
    - $\rightarrow$  comme pour ISD en Hamming : améliore la complexité car plus facile à trouver.

## Attaque sur le support

### Détail :

Recherche d'une erreur  $e'$  de rang :  $r' \geq r$  avec  $r'n \leq m(n-k)$ .

$$e' = \beta U \rightarrow HU^t \beta^t = Hy^t$$

avec  $\beta$  une base de rang  $r'$  dans  $\mathbb{F}_q^m$  et  $U$  une matrice  $r' \times n$  dans  $\mathbb{F}_q$ .

Opérations :

- Plus de supports à tester :  $q^{(r-1)(m-r)} \rightarrow q^{(r'-1)(m-r')}$
- Meilleure Probabilité de trouver :  $\frac{1}{q^{(r-1)(m-r)}} \rightarrow \frac{q^{(r'-m)}}{q^{(r-1)(m-r)}}$

La complexité est donc :

$$\min\left((n-k)^3 m^3 q^{r \frac{\lfloor km \rfloor}{n}}, (n-k)^3 m^3 q^{(r-1) \frac{\lfloor (k+1)m \rfloor}{n}}\right)$$

# Attaque sur le support

## Conclusion sur la première attaque

- Amélioration des deux attaques de OJ '02.
- attaques exponentielles dans le cas général
- Complexité :  $\min\left((n-k)^3 m^3 q^{r \lfloor \frac{km}{n} \rfloor}, (n-k)^3 m^3 q^{(r-1) \lfloor \frac{(k+1)m}{n} \rfloor}\right)$

## Comparaison avec les anciennes complexités :

- énumération des bases :  $\leq (k+r)^3 q^{(r-1)(m-r)+2}$
- énumération des coordonnées :  $\leq (k+r)^3 r^3 q^{(r-1)(k+1)}$

**Remarque** : dans le cas où  $n = m$  même complexité exponentielle que l'énumération des coordonnées de OJ '02

## Attaques algébriques pour la métrique rang

**difficulté : comment traduire en équations le fait qu'un vecteur appartienne à un sev de dimension donnée de  $\mathbb{F}_{q^m}$  ?**

- Plusieurs possibilités qui se ramènent à résoudre un système d'équations sur le petit corps  $\mathbb{F}_q$

**Pb** : casser la structure du gros corps implique plus d'inconnues : au moins  $n \times r$

En pratique devient vite ingérable pour la résolution dès que  $r \geq 3$  (Levy-dit-Vehel-Perret '06) car la complexité est exponentielle (en general) dans le nombre d'inconnues.

- Nécessité de trouver une nouvelle mise en équation plus adaptée au problème

# Attaque par $q$ -polynômes

## $q$ -polynôme

Un  $q$ -polynôme est un polynôme de la forme  $P(x) = \sum_{i=0}^r p_i x^{q^i}$  avec  $p_i \in \mathbb{F}_{q^m}$ .

- Linéarité :  $P(\alpha x + \beta y) = \alpha P(x) + \beta P(y)$  avec  $x, y \in \mathbb{F}_{q^m}$  et  $\alpha, \beta \in \mathbb{F}_q$ .
- $\forall B$  base de  $r$  vecteurs de  $\mathbb{F}_{q^m}$ ,  $\exists ! P$   $q$ -polynôme unitaire de degré  $q^r$  tel que  $\forall b \in B, P(b) = 0$ .

On peut donc définir un sous-espace vectoriel de dimension  $r$  à l'aide d'un polynôme de  $q$ -degré  $r$ .

## Attaque par $q$ -polynômes

Reformulation du problème :

$$c + e = y$$

avec  $c$  un mot du code  $\mathcal{C}$ ,  $e$  un mot de poids  $r$  et  $y$  connu.  
Il existe un polynôme  $P$  de  $q$ -degré  $r$  tel que

$$P(c - y) = 0$$

de plus il existe  $x \in \mathbb{F}_{q^m}^k$  tel que  $c = xG$ , ce qui donne :

$$\left( \sum_{i=0}^r p_i (xG_1 - y_1)^{q^i}, \dots, \sum_{i=0}^r p_i (xG_n - y_n)^{q^i} \right)$$

avec  $x \in \mathbb{F}_{q^m}^k$ ,  $G_j$  la  $j$ -ième colonne de  $G$  et  $y \in \mathbb{F}_{q^m}^n$  connu.

# Attaque par $q$ -polynômes

**Avantages** : moins d'inconnues, des équations creuses,  
semi-régulier

**Inconvénient** : des équations de degré  $q^r + 1$

Deux types de méthode pour le résoudre :

- Linéarisation et Linéarisation hybride
- Bases de gröbner et Bases de gröbner hybrides

Méthode hybride : énumération partielle des inconnues

## Linéarisation

- **Traiter les monômes comme des inconnues indépendantes.**

$$\sum_{i=0}^r p_i (\sum_{t=1}^k x_t g_{j,t} - y_j)^{q^i}, \text{ } j\text{-ième équation}$$

- $x_t$  : les  $k$  inconnues dans  $\mathbb{F}_{q^m}$ .
- $g_{j,t}$  : les  $n \times k$  coefficients connus de la matrice génératrice  $G$ .
- $y_j$  : les  $n$  éléments de  $\mathbb{F}_{q^m}$  connus dans le problème.
- $p_i$  : les  $r + 1$  coefficients inconnus du polynôme, avec  $p_r = 1$ .

Attaque : linéarisation des monomes  $x_t^{q^i} p_i$  et  $p_i$ .

### attaque par linéarisation

*Si  $n \geq (r + 1)(k + 1) - 1$ , la complexité de cette attaque est en  $((r + 1)(k + 1) - 1)^3$  opérations dans  $\mathbb{F}_{q^m}$ .*

## Linéarisation hybride

**Idée** : deviner une coordonnée de l'erreur  $e$  afin de diminuer le nombre d'inconnues du problème.

Problème :

$$c + e = y$$

avec  $c_j = \sum_{t=1}^k x_t g_{t,j}$  car  $c \in \mathcal{C}$ .

En combinant les équations on obtient pour chaque coordonnée  $j$  :

$$\sum_{t=1}^k x_t g_{j,t} + e_j = y_j$$

## Linéarisation hybride

$$\sum_{t=1}^k x_t g_{j,t} + e_j = y_j$$

- Connaître  $e_j$  donne une équation supplémentaire sur les  $x_t$
- Chaque équation supprime  $r$  monômes ( $x_t^{q^i} p_i$ ).
- Le nombre de valeurs que peut prendre l'erreur est :  $q^r$ .

**Deviner une erreur est moins coûteux que de deviner une inconnue.**

### attaque hybride

*Si  $\lceil \frac{(r+1)(k+1)-(n+1)}{r} \rceil \leq k$  cette attaque permet de résoudre le problème en  $r^3 k^3 q^{r \lceil \frac{(r+1)(k+1)-(n+1)}{r} \rceil}$ .*

# Bases de Gröbner

**Les bases de Gröbner permettent de résoudre des systèmes d'équations non linéaires.**

Nous avons  $k + r$  inconnues et  $n$  équations creuses de degré  $q^r + 1$  de la forme :

$$\sum_{i=0}^r p_i \left( \sum_{t=1}^k x_t g_{j,t} - y_j \right)^{q^i}$$

Utilisation de l'algorithme  $F4$  dans MAGMA pour obtenir des bases de Gröbner à partir des équations du problème.

**méthode hybride** : efficace car le rapport inconnue/équation se ressent bien pour les bases de Gröbner

# Application à la cryptanalyse

- **Cryptosystème GPT '91** (utilise les codes de Gabidulin - analogue de McEliece avec RS)

**Intêret** : petite taille de clés (quelques milliers de bits)

Différents types d'attaques :

- attaques sur le mot : on essaie de décoder avec les attaques génériques (type OJ)
- attaques structurelles : on essaie de retrouver la structure cachée

## Application à la cryptanalyse

- nombreuses variations (type de masquage) sur le système
    - en 2005 Overbeke donne une attaque structurelle très efficace qui casse tous les paramètres proposés
    - 2008 et après : réparations et nouveaux types de masquage résistant à l'attaque d'Overbeke
  - 2 familles de paramètres connus :
    - Loidreau (PQC '10)
    - Haitham Rashwan, Ernst M. Gabidulin, Bahram Honary ISIT '09,'10
- on montre que nos attaques génériques cassent toutes les nouveaux paramètres proposés

## Résultats

Paramètres proposés par Pierre Loidreau (PQC '10)

Code $[n, k, r]_m$	OJ1	OJ2	Over	ES	L	LH	HGb
$[64, 12, 6]_{24}$	$2^{104}$	$2^{85}$	$2^{80}$	$2^{50}$	non	$2^{48}$	2 heures
$[76, 12, 6]_{24}$	$2^{104}$	$2^{85}$	$2^{80}$	$2^{49}$	non	$2^{36}$	1 seconde

Paramètres proposés par Haitham Rashwan, Ernst M. Gabidulin,  
Bahram Honary ISIT '09,'10

Code $[n, k, r]_m$	Over	ES	L	LH	HGb
$[28, 14, 3]_{24}$	$2^{80}$	$2^{55}$	non	$2^{49}$	2 jours
$[28, 14, 4]_{24}$	$2^{80}$	$2^{70}$	non	$2^{65}$	pas fini
$[20, 10, 4]_{24}$	$2^{80}$	$2^{56}$	non	$2^{51}$	5 jours
$[20, 12, 4]_{24}$	$2^{80}$	$2^{60}$	non	$2^{60}$	pas fini

## Conclusion

- Les 2 attaques connues ont été généralisées en une seule
- Les attaques dépendent maintenant de tous les paramètres du problème
- Une meilleure compréhension du problème de décodage par syndrome en métrique rang
- Une nouvelle formulation de ce problème qui permet des attaques algébriques plus efficaces
- Cryptanalyse de tous les paramètres proposés pour réparer le cryptosystème de Gabidulin