

Cryptanalyse algébrique des systèmes basés sur les codes

Soutenance de stage

Stage encadré par Jean-Charles Faugère, Ludovic Perret (LIP6),
Jean-Pierre Tillich et Ayoub Otmani (INRIA)

Mohamed Amine Najahi

Université Pierre et Marie Curie

Mardi, 6 septembre 2011



- 1 Introduction
- 2 Cryptographie basée sur la théorie des codes
- 3 La variante dyadique
- 4 Attaque de la variante dyadique
- 5 Conclusion

Sommaire

- 1 Introduction
- 2 Cryptographie basée sur la théorie des codes
- 3 La variante dyadique
- 4 Attaque de la variante dyadique
- 5 Conclusion

Enjeux de la cryptographie à clef publique

Constats

- 1 Les cryptosystèmes à clef publique reposent sur un problème difficile avec trappe.
- 2 La majorité des problèmes exploités aujourd'hui sont issus de la théorie des nombres (factorisation, logarithme discret, courbes elliptiques ...).
- 3 En 1994, Shor a publié un algorithme quantique de factorisation et de résolution de logarithme discret en temps polynômial.

↔ une grande partie des cryptosystèmes à clef publique en usage aujourd'hui sera obsolète si l'on construisait un ordinateur quantique.

Solutions : Cryptosystèmes post-quantiques

Des alternatives sont fournies par :

- Les codes correcteurs d'erreurs.
- Les réseaux euclidiens.
- Les systèmes polynômiaux.
- ...

Enjeux de la cryptographie à clef publique

Constats

- 1 Les cryptosystèmes à clef publique reposent sur un problème difficile avec trappe.
- 2 La majorité des problèmes exploités aujourd'hui sont issus de la théorie des nombres (factorisation, logarithme discret, courbes elliptiques ...).
- 3 En 1994, Shor a publié un algorithme quantique de factorisation et de résolution de logarithme discret en temps polynômial.

↪ une grande partie des cryptosystèmes à clef publique en usage aujourd'hui sera obsolète si l'on construisait un ordinateur quantique.

Solutions : Cryptosystèmes post-quantiques

Des alternatives sont fournies par :

- Les codes correcteurs d'erreurs.
- Les réseaux euclidiens.
- Les systèmes polynômiaux.
- ...

Sommaire

- 1 Introduction
- 2 Cryptographie basée sur la théorie des codes**
- 3 La variante dyadique
- 4 Attaque de la variante dyadique
- 5 Conclusion

Théorie des codes correcteurs

Principe

- Codage : Ajouter de la redondance à un message avant de le transmettre sur un canal bruité.
- Décodage : Retrouver le message initial à partir du message (probablement erroné) reçu.

34

The Mathematical Theory of Communication




Fig. 1. — Schematic diagram of a general communication system.

Théorie des codes correcteurs d'erreurs

Codes linéaires

Un code linéaire \mathcal{C} est un sous-espace vectoriel de dimension k de \mathbb{F}_q^n .

- n la longueur du code
- k la dimension du code
- \mathbb{F}_q l'alphabet du code
- d la distance minimale du code (métrique de Hamming)

On le note $\mathcal{C} = [n, k, d]_q$

Propriétés

- détecte $d - 1$ erreurs.
- corrige de manière unique jusqu'à $\lfloor \frac{d-1}{2} \rfloor$ erreurs.
- admet une base de k vecteurs de longueur $n \implies$ Matrice génératrice G .
 - ▶ Les mots du codes sont tous les vecteurs xG où $x \in \mathbb{F}_q^{1 \times k}$.
- est le noyau d'une matrice de rang $n - k \implies$ Matrice de parité.
 - ▶ m est un mot du code $\Leftrightarrow mH^T = 0$. En particulier $G \cdot H^T = (0)^{k, n-k}$.

Quelques problèmes difficiles issus de la théorie des codes

Problème du décodage

Berlekamp, McEliece, Van Tilborg '78 : Étant donné la matrice génératrice G d'un code linéaire aléatoire de longueur n et un message m de même longueur.

▷ Le problème du décodage (*i.e.* déterminer le mot du code le plus proche de m) est NP-Complet.

Problème de la distance minimale

Vardy '97 : Étant donné la matrice génératrice G d'un code linéaire aléatoire.

▷ Le problème de déterminer sa distance minimale est NP-Complet.

Rappel sur les codes de Goppa classique

C'est une sous-famille des codes alternants \Rightarrow admet un algorithme de décodage efficace jusqu'à la distance minimale construite.

Définition des codes de Goppa

On se donne une séquence $X = (x_0, \dots, x_{n-1}) \in \mathbb{F}_{p^m}$ et un polynôme $g(x) \in \mathbb{F}_{p^m}[x]$ de degré t tel que $g(x_i) \neq 0 \forall i$. Le code de Goppa $\Gamma(X, g)$ est le code de matrice de parité :

$$H = \begin{pmatrix} g(x_0)^{-1} & \cdots & g(x_{n-1})^{-1} \\ g(x_0)^{-1}x_0 & \cdots & g(x_{n-1})^{-1}x_{n-1} \\ \vdots & \ddots & \vdots \\ g(x_0)^{-1}x_0^{t-1} & \cdots & g(x_{n-1})^{-1}x_{n-1}^{t-1} \end{pmatrix} \in \mathbb{F}_{p^m}^{t \times n}$$

Distance minimale des codes de Goppa

- Sur un corps de caractéristique impaire :
 - ▶ Un code de Goppa a une distance minimale construite égale à $t + 1$.
- Sur un corps binaire :
 - ▶ Un code de Goppa a une distance minimale construite égale à $2t + 1$, si g n'a pas de racines multiples.

McEliece et Niederreiter

On se donne un code $\mathcal{C} = [n, k, d = 2t + 1]$ décodable efficacement et on note :

$G \in \mathbb{F}_q^{k \times n}$ sa matrice génératrice.

$H \in \mathbb{F}_q^{n-k \times n}$ sa matrice de parité.

S une matrice inversible et P une matrice de permutation.

	<i>McEliece '78</i>	<i>Niederreiter '86</i>
Public key	$(\tilde{G} = SGP, t)$	$(\tilde{H} = SHP, t)$
Private key	$S \in GL_k(\mathbb{F}_q), G, P \in \mathbb{F}_q^{n \times n}$	$S \in GL_{n-k}(\mathbb{F}_q), H, P \in \mathbb{F}_q^{n \times n}$
Chiffrement	$c = m\tilde{G} + e, m \in \mathbb{F}_q^k, w(e) = t$	$c = \tilde{H}m^T, m \in \mathbb{F}_q^n, w(m) = t$
Déchiffement	$m = Dec(cP^{-1})S^{-1}$	$m = P^{-1}DecSyn(S^{-1}c)$

La signature CFS(Courtois, Finiasz, Sendrier)

C'est un schéma de signature basé sur le cryptosystème de Niederreiter et une fonction de hachage $\mathcal{H} : \{0, 1\}^* \times \mathbb{N} \rightarrow \mathbb{F}_q^k$

CFS

On peut la voir comme 3 algorithmes distincts :

- **Keygen** : Produit le couple (H, \mathcal{T}) : H la matrice de parité d'un code $\mathcal{C} = [n, k, 2t + 1]_q$, et \mathcal{T} une trappe qui permet de le décoder.
- **Sign** : Soit m le message à signer.
 - ▶ Trouve $c \in \mathbb{N}$ t.q. $syn = \mathcal{H}(m, c)$ est un syndrome décodable.
 - ▶ Utilise \mathcal{T} pour obtenir e t.q. $w(e) \leq t$ et $He^T = syn^T$.
 - ▶ La signature est (e, c) .
- **Verify** : Accepte la signature si et seulement si $w(e) \leq t$ et $He^T = \mathcal{H}(m, c)^T$

Quels paramètres pour CFS

Dans le cas Goppa binaire :

$$\text{La densité des syndromes décodables est } d = \frac{1}{2^{mt}} \sum_{w=1}^t \binom{n}{w} \approx \frac{n^t}{2^{mt} t!} \approx \frac{1}{t!}$$

↪ $t!$ est le nombre moyen d'essais avant d'obtenir la signature.

Avantages et inconvénients des primitives basées sur les codes

Constats

Principal avantage : Rapidité dans le chiffrement (produit matrice vecteur).

Principal inconvénient : La taille des clefs publiques.

Solutions proposées par de récents travaux

- Ajouter de la structure sur la matrice publique pour réduire sa taille.
 - ▶ Quasi-cyclicité (Berger *et al.*, AFRICACRYPT 2009)
 - ▶ Quasi-dyadicité (Barreto *et al.*, SAC 2009)
- Utiliser des codes de Goppa non-binaires.
 - ▶ Wild McEliece (Bernstein *et al.*, SAC 2010)
- ...

Faugère, Perret, Otmani et Tillich

- La plupart des paramètres quasi-cycliques et quasi-dyadiques destinés au chiffrement ont été cassés. (Eurocrypt 2010)
 - ▶ Les paramètres quasi-dyadiques binaires résistent encore.
- Un distingueur pour certains codes de Goppa a aussi été proposé. (YACC 2010)

Sommaire

- 1 Introduction
- 2 Cryptographie basée sur la théorie des codes
- 3 La variante dyadique**
- 4 Attaque de la variante dyadique
- 5 Conclusion


Matrice de Cauchy et codes de Goppa

Définition

Soit $m \in \mathbb{F}_q^n$ un vecteur. On dit que la matrice carré M est dyadique si

$$M = (m_{i,j}) = (m_{i \oplus j}).$$

Une matrice dyadique est totalement déterminée par sa première ligne, on appelle celle-ci la signature.



Condition pour que la matrice de McEliece soit dyadique (Barreto *et al.*, SAC 2009)

$$\frac{1}{m_{i \oplus j}} = \frac{1}{m_i} + \frac{1}{m_j} + \frac{1}{m_0}$$

Sommaire

- 1 Introduction
- 2 Cryptographie basée sur la théorie des codes
- 3 La variante dyadique
- 4 Attaque de la variante dyadique**
- 5 Conclusion

Les attaques sur les primitives basées sur les codes

Attaques par décodage

- 1 Information Set Decoding (Stern, Canteaut, ...)
- 2 Generalized Birthday Attacks (Wagner, ...)
- 3 ...

Attaques structurelles

Essayer de recouvrer la clef secrète en exploitant la structure de la clef publique.

- Support splitting algorithm (Sendrier)

Principe de l'attaque algébrique

Modélisation du cryptosystème par un système d'équations algébriques tel que :
Résoudre ce système \implies Recouvrer une information secrète.

2 étapes

- Modélisation :
 - ▶ Tout cryptosystème peut être modélisé par un système d'équations polynômiales.
- Résolution :
 - ▶ Les bases de Gröbner (Algorithme de Buchberger et plus récemment F4 et F5 de Faugère).
 - Les SAT solvers dans le cas booléen.
 - La linéarisation.

Les attaques sur les primitives basées sur les codes

Attaques par décodage

- 1 Information Set Decoding (Stern, Canteaut, ...)
- 2 Generalized Birthday Attacks (Wagner, ...)
- 3 ...

Attaques structurelles

Essayer de recouvrer la clef secrète en exploitant la structure de la clef publique.

- Support splitting algorithm (Sendrier)

Principe de l'attaque algébrique

Modélisation du cryptosystème par un système d'équations algébriques tel que :
Résoudre ce système \implies Recouvrer une information secrète.

2 étapes

- Modélisation :
 - ▶ Tout cryptosystème peut être modélisé par un système d'équations polynômiales.
- Résolution :
 - ▶ Les bases de Gröbner (Algorithme de Buchberger et plus récemment F4 et F5 de Faugère).
 - Les SAT solvers dans le cas booléen.
 - La linéarisation.

Objectif

L'objectif de l'attaque est de recouvrir le vecteur \tilde{h} qui a servi à la construction de la matrice publique.

- Trouver la meilleure modélisation.
- Utiliser le meilleur outils pour la résolution.

Comment

La première étape, toujours possible est d'utiliser la relation fondamentale suivante

$$G \cdot H^T = (0)^{k, n-k}$$

H est dyadique, on s'intéressera à sa première ligne

$$X := (x_0, \dots, x_{n-1}) \in \mathbb{F}_{q^m}[x_1, \dots, x_{n-1}].$$

On dispose de la matrice génératrice G sous la forme systématique suivante :

$$G = \begin{pmatrix} & 1 & 0 & \dots & \dots & 0 \\ & 0 & 1 & \dots & \dots & 0 \\ P \in \mathbb{F}_2^{k \times k} & \vdots & \vdots & \ddots & \dots & 0 \\ & 0 & 0 & \dots & \dots & 1 \end{pmatrix} \in \mathbb{F}_2^{k \times n} \quad \sum_{j=0}^{n-k-1} p_{i,j} x_j + x_{n-k+i} = 0 \forall 0 \leq i \leq k-1$$

On a exprimé linéairement k variables inconnues en fonction de $n - k = mt$ variables.

Deux types d'équations sont dérivés de la structure dyadique de la matrice.

Équations inter-blocs

$$\frac{1}{h_{bt+i\oplus j}} = \frac{1}{h_{bt\oplus i}} + \frac{1}{h_{bt\oplus j}} + \frac{1}{h_{bt}}$$

Équations intra-blocs

$$\frac{1}{h_{bt+i}} + \frac{1}{h_{bt}} = \frac{1}{h_i} + \frac{1}{h_0}$$

Scénario de l'attaque (premier bloc connu)

On suppose que l'on connaît $h_0, \dots, h_{t-1} \rightsquigarrow$ coût en $2^{m(\log(t)-1)}$

Des équations quadratiques avec comme paramètres :

Nombre de variables $\Rightarrow n - k - t = (m - 1)t$

Nombre d'équations $\Rightarrow \binom{n}{t} - 1 \times (t - 1)$

Résolution du système

Résolution par linéarisation tableau

C'est une méthode de résolution des systèmes sur-déterminés.

applicable si $\rightsquigarrow \left(\frac{2^m-t}{t} - 1\right) \times (t-1) \geq \binom{(m-1)t+2}{2}$

	m
$t = 4$	≥ 10
$t = 8$	≥ 13
$t = 16$	≥ 15

Valeurs de m et t pour lesquelles l'inégalité est vérifiée.

Impact sur la sécurité

m	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
$t = 4$	$2^{20.8}$	$2^{22.2}$	$2^{23.6}$	$2^{24.9}$	$2^{26.2}$	$2^{27.5}$	$2^{28.7}$	2^{30}	$2^{31.2}$	$2^{32.4}$	$2^{33.6}$	$2^{34.8}$	2^{36}	$2^{37.1}$	$2^{38.3}$	$2^{39.4}$	$2^{40.6}$
$t = 8$				$2^{39.3}$	$2^{41.6}$	$2^{43.9}$	$2^{46.1}$	$2^{48.4}$	$2^{50.6}$	$2^{52.8}$	2^{55}	$2^{57.2}$	$2^{59.3}$	$2^{61.5}$	$2^{63.7}$	$2^{65.8}$	2^{68}
$t = 16$							$2^{63.5}$	$2^{66.7}$	2^{70}	$2^{73.2}$	$2^{76.4}$	$2^{79.5}$	$2^{82.7}$	$2^{85.9}$	2^{89}	$2^{92.2}$	$2^{95.3}$

Complexité de résolution par linéarisation ($\omega = 2, 376$).

On a aussi réussi à ramener le cas $t = 12$ au cas $t = 4$

Sommaire

- 1 Introduction
- 2 Cryptographie basée sur la théorie des codes
- 3 La variante dyadique
- 4 Attaque de la variante dyadique
- 5 Conclusion

Conclusion

- Nous avons implémenté la variante dyadique de CFS en magma.
- Nous avons proposé quelques améliorations à l'algorithme de génération des clefs.
- Nous avons proposé une attaque structurelle sur la variante dyadique de McEliece destinée à la signature.
- Nous avons implémenté l'attaque et l'avons testé sur plusieurs valeurs.
- Les expériences corroborent l'analyse théorique. La linéarisation a été efficace pour la résolution de la plupart des paramètres.
- Faugère *et al.* ont réussi à casser la plupart des paramètres dyadiques destinés au chiffrement. Nous avons montré la vulnérabilité des paramètres destinés à CFS.

Conclusion

- Nous avons implémenté la variante dyadique de CFS en magma.
- Nous avons proposé quelques améliorations à l'algorithme de génération des clefs.
- Nous avons proposé une attaque structurelle sur la variante dyadique de McEliece destinée à la signature.
- Nous avons implémenté l'attaque et l'avons testé sur plusieurs valeurs.
- Les expériences corroborent l'analyse théorique. La linéarisation a été efficace pour la résolution de la plupart des paramètres.
- Faugère *et al.* ont réussi à casser la plupart des paramètres dyadiques destinés au chiffrement. Nous avons montré la vulnérabilité des paramètres destinés à CFS.

Conclusion

- Nous avons implémenté la variante dyadique de CFS en magma.
- Nous avons proposé quelques améliorations à l'algorithme de génération des clefs.
- Nous avons proposé une attaque structurelle sur la variante dyadique de McEliece destinée à la signature.
- Nous avons implémenté l'attaque et l'avons testé sur plusieurs valeurs.
- Les expériences corroborent l'analyse théorique. La linéarisation a été efficace pour la résolution de la plupart des paramètres.
- Faugère *et al.* ont réussi à casser la plupart des paramètres dyadiques destinés au chiffrement. Nous avons montré la vulnérabilité des paramètres destinés à CFS.