Sécurité et systèmes embarqués

Pablo Rauzy
pr@up8.edu
pablo.rauzy.name/teaching/sese

UFR MITSIC / M1 informatique

Séance 0

Présentation du cours
Chiffrement par substitution

Présentation du cours

La cryptologie

- Étymologiquement, c'est "la science du secret".
- Un art ancien : les premiers documents chiffrés qu'on retrouve datent de l'Antiquité.
- Une science récente : sujet de recherche académique seulement depuis les années 60.
- La cryptologie étudie notamment
  - la *confidentialité*,
  - l'*authentification*,
  - la *non-répudiation*,
  - l'*intégrité*,
  - la *preuve à divulgation nulle de connaissance*, et
  - l'*anonymat*.

La cryptologie

- Étymologiquement, c'est "la science du secret".
- Un art ancien : les premiers documents chiffrés qu'on retrouve datent de l'Antiquité.
- Une science récente : sujet de recherche académique seulement depuis les années 60.
- La cryptologie étudie notamment
  - la *confidentialité*,
  - l'*authentification*,
  - la *non-répudiation*,
  - l'*intégrité*,
  - la *preuve à divulgation nulle de connaissance*, et
  - l'*anonymat*.
- Ses deux branches principales sont
  - la *cryptographie*, et
  - la *cryptanalyse*.

La cryptographie

- Étymologiquement, “l’écriture secrète”.
- Le but de cette discipline est de protéger les messages, en assurant leurs
  - confidentialité,
  - authenticité, et
  - intégrité.
- La cryptographie moderne utilise des *clefs*.
- Il y a deux grandes familles :
  - la cryptographie *symétrique* (à clef *secrète*), et
  - la cryptographie *asymétrique* (à clefs *publique* et *privée*).
- La cryptographie s’occupe principalement de la mise au point d’*algorithmes* et de *protocoles* permettant le chiffrement, de déchiffrement, et l’échange de messages.

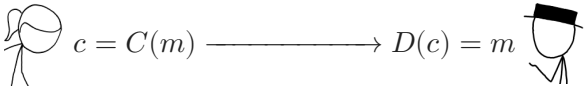

La cryptanalyse

- Étymologiquement, “défaire le secret”.
- Le but de cette discipline est de casser la cryptographie.
  - C’est à dire décrypter un message chiffré, sans connaître la clef de chiffrement.
  - On appelle ce processus une *attaque*.
- On catégorise souvent les attaques par ce à quoi l’attaquant a accès :
  - seulement des messages chiffrés,
  - certaines correspondances entre messages clairs et chiffrés,
  - certaines correspondances entre messages clairs choisis et leur chiffré,
  - certaines correspondances entre messages chiffrés choisis et leur clair,
- Il existe de nombreuses techniques d’attaques, mais on peut distinguer deux familles :
  - la cryptanalyse *classique*, et
  - les attaques par canaux auxiliaires.

Les systèmes embarqués

- Un *système embarqué* est un système électronique ou informatique autonome.
- Il est souvent très spécialisé (couches logiciel et matériel très liées).
- Il y en a partout :
  - smartcards (cartes bancaires, cartes téléphoniques, cartes SIM, décodeurs, ...),
  - appareils mobiles (téléphones, tablettes, consoles portables, ...),
  - systèmes temps réels (ascenseurs, voitures, trains, navigation aérienne...),
  - équipements (imprimantes, copieurs, téléphones, contrôle d'accès par badges...)
- Du coup, de nombreuses contraintes :
  - coût,
  - ressources limités (espace, puissance de calcul, autonomie),
  - sûrement de fonctionnement,
  - sécurité.

Les systèmes embarqués

- Un *système embarqué* est un système électronique ou informatique autonome.
- Il est souvent très spécialisé (couches logiciel et matériel très liées).
- Il y en a partout :
  - smartcards (cartes bancaires, cartes téléphoniques, cartes SIM, décodeurs, ...),
  - appareils mobiles (téléphones, tablettes, consoles portables, ...),
  - systèmes temps réels (ascenseurs, voitures, trains, navigation aérienne...),
  - équipements (imprimantes, copieurs, téléphones, contrôle d'accès par badges...)
- Du coup, de nombreuses contraintes :
  - coût,
  - ressources limités (espace, puissance de calcul, autonomie),
  - sûrement de fonctionnement,
  - sécurité.

- Au niveau de la sécurité, les systèmes embarqués ont une particularité forte.
- Ils peuvent très facilement se retrouver entre les mains de l'attaquant.

- Au niveau de la sécurité, les systèmes embarqués ont une particularité forte.
- Ils peuvent très facilement se retrouver entre les mains de l'attaquant.
- Cela signifie que l'on sort du cadre de la cryptanalyse classique.
- Lors des opérations de chiffrement et déchiffrement, l'attaquant à accès au système.

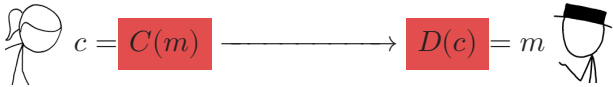

Les attaques par canaux auxiliaires

- Ici, on suppose la robustesse théorique de la cryptographie.
- En revanche, on cherche à exploiter des failles au niveau de l'*implémentation*.
- Aussi bien au niveau logiciel que matériel.
- Il existe différentes catégories d'attaques par canaux auxiliaires passives :
  - analyse de temps de calcul,
  - analyse de consommation de courant,
  - analyse des émanations électromagnétiques,
  - analyse acoustique ou lumineuse ;
- ainsi qu'active :
  - injection de fautes,
  - sondage (attaque invasive).

Ce cours

- Objectifs :
  - Introduction à la cryptologie.
  - Comprendre les problématiques de sécurité liées aux systèmes embarqués.
  - Connaître les attaques physiques et comment tenter de s'en protéger.

- 10 séances :
  - Présentation du cours / Chiffrement par substitution
  - Cryptographie symétrique
  - Cryptographie asymétrique
  - Cryptanalyse classique
  - TP cryptographie
  - Attaques par canaux auxiliaires
  - TP canaux auxiliaires
  - Attaques par injection de fautes
  - TP injection de fautes
  - Ouvertures sur la sécurité

- Votre évaluation pour ce cours prendra en compte :
  - les TPs,
  - un rapport sur un article de recherche.

Ce qui est attendu de vous

- Une connaissance solide des bases de la cryptographie :
  - Connaître les points forts et faiblesses des différentes familles d'algorithmes.
  - Comprendre le fonctionnement des principaux algorithmes.
- Une connaissance des enjeux de sécurité des systèmes embarqués :
  - Comprendre les failles qui peuvent se révéler au niveau physique.
  - Connaître les principales méthodes d'exploitations et de protections.

Chiffrement par substitution

- *16ème siècle AEC :* premier document chiffré connu.
  C'est une tablette d'argile, retrouvée en Irak, avec la recette d'un potier. L'orthographe des mots y est changée (notamment, il manque les consonnes).

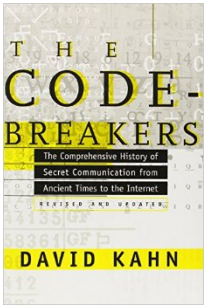

Un peu d'histoire

- *16ème siècle AEC :* premier document chiffré connu.
  C'est une tablette d'argile, retrouvée en Irak, avec la recette d'un potier. L'orthographe des mots y est changée (notamment, il manque les consonnes).
- *10ème à 8ème siècles AEC :* les scytales, chez les grecs.

Un peu d'histoire

- *16ème siècle AEC :* premier document chiffré connu.
  C'est une tablette d'argile, retrouvée en Irak, avec la recette d'un potier. L'orthographe des mots y est changée (notamment, il manque les consonnes).
- *10ème à 8ème siècles AEC :* les scytales, chez les grecs.
- *5ème siècle AEC :* plusieurs façons de chiffrer dont *atbash*, chez les Hébreux. Il s'agit d'utiliser l'alphabet à l'envers (A devient Z, B devient Y, etc.)

Un peu d'histoire

- *16ème siècle AEC :* premier document chiffré connu.
  C'est une tablette d'argile, retrouvée en Irak, avec la recette d'un potier. L'orthographe des mots y est changée (notamment, il manque les consonnes).
- *10ème à 8ème siècles AEC :* les scytales, chez les grecs.
- *5ème siècle AEC :* plusieurs façons de chiffrer dont *atbash*, chez les Hébreux. Il s'agit d'utiliser l'alphabet à l'envers (A devient Z, B devient Y, etc.)
- Après ça, arrivent des les premiers "vrais" systèmes de chiffrement.

Les premiers “vrais” cryptosystèmes

- Les premiers *cryptosystèmes* fonctionnent essentiellement par substitution.
- Il existe trois types de substitutions :
  - *monoalphabétique :* chaque lettre est remplacée par une autre,
  - *polyalphabétique :* une suite de substitutions monoalphabétiques est réutilisées en boucle,
  - *polygramme :* substitue des groupes de lettres par d’autres.

- C'est le chiffrement par substitution le plus ancien connu (1er siècle AEC).
- Il était utilisé dans l'armée romaine (d'où son nom).
- Très faible, mais fonctionne bien en pratique grâce au faible taux d'alphabétisation dans la population.
- La clef est un nombre en 1 et 26 (A et Z).
- On opère un décalage circulaire de chaque lettre par la clef.
- Encore utilisé de nos jour avec ROT13 :).

- Décrit pour la première fois vers 150 AEC.
- Utilisé par plusieurs civilisations de différentes manières.
- Dans sa forme la plus simple, il s’agit de substituer chaque lettre par ses coordonnées dans un carré de 5×5.
- Une variante avec clef existe, où on se sert de la clef pour commencer à remplir le tableau.
- Une utilisation intéressante encore de nos jours de ce système est la communication simple à distance avec torches, drapeaux, ou du son.

	1	**2**	**3**	**4**	**5**
1	A	B	C	D	E
2	F	G	H	I/J	K
3	L	M	N	O	P
4	Q	R	S	T	U
5	V	W	X	Y	Z

“informatique” devient “24332134423211442441451 5”

- Décrit pour la première fois vers 150 AEC.
- Utilisé par plusieurs civilisations de différentes manières.
- Dans sa forme la plus simple, il s’agit de substituer chaque lettre par ses coordonnées dans un carré de 5×5.
- Une variante avec clef existe, où on se sert de la clef pour commencer à remplir le tableau (ci-dessous avec la clef “wikipedia”).
- Une utilisation intéressante encore de nos jours de ce système est la communication simple à distance avec torches, drapeaux, ou du son.

	1	**2**	**3**	**4**	**5**
1	W	I/J	K	P	E
2	D	A	B	C	F
3	G	H	L	M	N
4	O	Q	R	S	T
5	U	V	X	Y	Z

“informatique” devient “123525414334224524124241115”

Le premier manuscrit traitant de cryptanalyse

- Au 9ème siècle, Al-Kindi écrit *Risalah fi Istikhraj al-Mu'amma* (Manuscrit sur le déchiffrement de messages cryptographiques).
- Il y fait la plus ancienne description de la méthode d'analyse de fréquences, et l'applique au chiffrement de César.

- Dans chaque langue, il y a des lettres qui reviennent plus souvent que d'autres.
- Par exemple en français le 'E' est la lettre la plus courante.

- Dans chaque langue, il y a des lettres qui reviennent plus souvent que d'autres.
- Par exemple en français le 'E' est la lettre la plus courante.
- On peut donc supposer que la lettre qui revient le plus dans le chiffré et un 'E', si on sait que le clair est en français.
- Si on ne connaît pas la langue d'origine du message, on peut calculer la fréquence de chaque lettre, et comparer cela avec les fréquences connues pour différentes langues.
- Il est aussi possible de le faire pour des tuples de lettre afin d'être encore plus précis.

Le chiffrement de Vigenère

- Cryptosystème polyalphabétique décrit en 1586 dans le *Traité sur les chiffres* de Blaise de Vigenère.
  - On trouve aussi une méthode similaire dans un texte de Giovan Battista Bellaso datant de 1533.
- Premier chiffrement à réellement introduire la notion de *clef*.
- La clef pouvant être au moins aussi longue que le message (en prenant comme référence un livre par exemple), le chiffrement de Vigenère résiste complètement à l'analyse de fréquences.
- En pratique, ce chiffrement a tenu près de 300 ans, jusqu'en 1863 quand Friedrich Kasiski publie une cryptanalyse du système.

- Message : “sécurité et systèmes embarqués”
- Clef : “Vigenère”

m	S	E	C	U	R	I	T	E	E	T	S	Y	S	T	E	M	E	S	E	M	B	A	R	Q	U	E	S
k	V	I	G	E	N	E	R	E	V	I	G	E	N	E	R	E	V	I	G	E	N	E	R	E	V	I	G
c	N	M	I	Y	E	M	K	I	Z	B	Y	C	F	X	V	Q	Z	A	K	Q	O	E	I	U	P	M	Y

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z
A	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z
B	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A
C	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B
D	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C
E	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D
F	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E
G	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F
H	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G
I	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H
J	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I
K	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J
L	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K
M	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L
N	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M
O	O	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N
P	P	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
Q	Q	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
R	R	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
S	S	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
T	T	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
U	U	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T
V	V	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U
W	W	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V
X	X	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W
Y	Y	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X
Z	Z	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y

- On suppose qu'on a uniquement les 26 lettres majuscules de l'alphabet.

1. Écrire une fonction C qui permet de chiffrer avec la méthode de Vigenère.
2. Écrire une fonction C qui permet de déchiffrer avec cette même méthode.
3. À quelle catégorie d'attaques ce cryptosystème peut résister ? Pourquoi ?

- On suppose qu'on a uniquement les 26 lettres majuscules de l'alphabet.

1. Écrire une fonction C qui permet de chiffrer avec la méthode de Vigenère.
2. Écrire une fonction C qui permet de déchiffrer avec cette même méthode.
3. À quelle catégorie d'attaques ce cryptosystème peut résister ? Pourquoi ?
4. Écrire une fonction C qui affiche la clef si on lui donne une paire clair/chiffré.

Cryptanalyse de Vigenère

- Il est possible de casser le chiffrement de Vigenère, mais il faut réduire le problème à l'analyse de fréquences.

Cryptanalyse de Vigenère

- Il est possible de casser le chiffrement de Vigenère, mais il faut réduire le problème à l'analyse de fréquences.
- C'est à dire se ramener dans le cas du chiffrement de César :
  - si la clef est de longueur l, $\forall d < l$, soit c_d la suite des lettres à un indice $i \equiv d \mod l$,
  - alors c_d est un chiffré de César utilisant comme décalage celui correspondant à la $d$ème lettre de la clef de Vigenère.
- Il faut donc retrouver la longueur de la clef.

Retrouver la longueur de la clef

- Pour retrouver la longueur de la clef, il y a besoin d'avoir un chiffré bien plus long que la clef.
- Ensuite il faut trouver des séquences de lettres qui se répètent.
- Si une séquence de lettre se répète plusieurs fois cela veut dire :
  - soit que la même séquence du clair a été chiffré avec la même partie de la clef,
  - soit que par hasard des séquences différentes du clair se retrouve chiffré de manière identique.
- En pratique sur les textes en langue naturelle, il suffit de trouver des séquences d'au moins 3 lettres pour que la probabilité de la seconde option soit très faible.

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :
  - WUU : 95

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :
  - WUU : 95
  - EEK : 200

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :
  - WUU : 95
  - EEK : 200
  - WXIZAYG : 190

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :
  - WUU : 95
  - EEK : 200
  - WXIZAYG : 190
  - NUOCZGM : 80

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :
  - WUU : 95
  - EEK : 200
  - WXIZAYG : 190
  - NUOCZGM : 80
  - GMU : 90

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

```
KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUDWUUMBSVLPS
NCMUEKQCTESWREEKOYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTDWXIZA
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGRWUUNEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSHNUOCZGMRUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFSTNUOCZGMDOEOYEEKCPJR
GPMURSKHFRSEIUEVGOYCWXIZAYGOSAANYDOEOYJLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVIDGMUCGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
WGMUSWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGOEEKJOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR
```

- Distances entre les répétitions :
  - WUU : 95
  - EEK : 200
  - WXIZAYG : 190
  - NUOCZGM : 80
  - GMU : 90
  - DOEOY : 45

Trouver des séquences répétées

- Prenons un exemple (tiré de Wikipédia) :

KQOWEFVJPUJUUNUKGLMEKJINMWUXFQMKJBGWRLFNFGHUD**WUU**MBSVLPS
NCMUEKQCTESWR**EEK**OYSSIWCTUAXYOTAPXPLWPNTCGOJBGFQHTD**WXIZA**
YGFFNSXCSEYNCTSSPNTUJNYTGGWZGR**WUU**NEJUUQEAPYMEKQHUIDUXFP
GUYTSMTFFSH**NUOCZGM**RUWEYTRGKMEEDCTVRECFBDJQCUSWVBPNLGOYL
SKMTEFVJJTWWMFMWPNMEMTMHRSPXFSSKFFST**NUOCZGMDOEOYEEK**CPJR
GPMURSKHFRSEIUEVGOYC**WXIZAYG**OSAANY**DOEOY**JLWUNHAMEBFELXYVL
WNOJNSIOFRWUCCESWKVID**GMU**CGOCRUWGNMAAFFVNSIUDEKQHCEUCPFC
MPVSUDGAVEMNYMAMVLFMAOYFNTQCUAFVFJNXKLNEIWCWODCCULWRIFT
W**GMU**SWOVMATNYBUHTCOCWFYTNMGYTQMKBBNLGFBTWOJFTWGNTEJKNEE
DCLDHWTYYIDGMVRDGMPLSWGJLAGO**EEK**JOFEKUYTAANYTDWIYBNLNYNP
WEBFNLFYNAJEBFR

- Distances entre les répétitions :
  - WUU : 95
  - EEK : 200
  - WXIZAYG : 190
  - NUOCZGM : 80
  - GMU : 90
  - DOEOY : 45
- PGCD(95, 200, 190, 80, 90, 45) = 5

- Soit c_i le texte des lettres à positions égale à i modulo 5 :
  - c_0 : KFJKKWMWFWSNKSKIAAWGFWYSYSJGWJAKDGMHZWGDEJWLSFWWMSSTZE
    KGSSVWYAEWMLWSWSDGWASKUMDMMATFXIDWWWTHWMMLWWJDWDDSAKKAWLWLJ
  - c_1 : QVUGJUKRGUVCQWOWXPPOQXGXNPNWUUPQUUTNGEKCCQVGKVWPTPKNGO
    CPKEGXGNOUEXNIUWGOGFIQCPGNVOQVKWCRGONTFGKGOGKCTGGWGJUNINEFE
  - c_2 : OJULIXJLHULMCRYCYXNJHIFCCNYZUUYHXYFUMYMTFCBOMJMNMXFUMY
    PMHIOIOYYNBYOOCKMCNFUHPVAYLYCFLCCIMVYCYYBFJNNLYMMGOOYYYYBYB
  - c_3 : WPNMNFBFUMPUTESTOPTBTZFSTTTGNQMUFTFORTEVBUPYTJFMHFFODE
    JUFUYZSDJHFVJFCVURMVDCFSVMFFUJNWUFUMBOTTBBFTEDYVPJEFTTBNFNF
  - c_4 : EUUEMQGNDBSEEESUTLCGDANESUGREEEIPSSCURERDSNLETMERSSCOE
    RRRECAAOLAELNREICUANEECUEAMNANEOLTSAUCNQNTTEEHIRLLEEADNPNAR

- Pour simplifier, on va le faire très simplement en cherchant juste les 'E' (qui est la lettre la plus courante en français).
- Avec la commande `fold` je peux couper le chiffré par ligne de 5 lettres.
- Avec la commande `cut` je peux isoler les caractères de la colonne i pour obtenir c_i.
- Ensuite avec les commandes `sort` et `uniq`, je peux trouver la lettre la plus utilisée.
- Si cette lettre est 'E', je retrouve le décalage du chiffrement de César.

- Pour simplifier, on va le faire très simplement en cherchant juste les 'E' (qui est la lettre la plus courante en français).
- Avec la commande `fold` je peux couper le chiffré par ligne de 5 lettres.
- Avec la commande `cut` je peux isoler les caractères de la colonne i pour obtenir c_i.
- Ensuite avec les commandes `sort` et `uniq`, je peux trouver la lettre la plus utilisée.
- Si cette lettre est 'E', je retrouve le décalage du chiffrement de César.
  - c_0 : `W` qui donnerait `S`
  - c_1 : `G` qui donnerait `C`
  - c_2 : `Y` qui donnerait `U`
  - c_3 : `F` qui donnerait `B`
  - c_4 : `E` qui donnerait `A`
- La clef serait donc SCUBA.

- On essaye de déchiffrer, si ça ne donne rien de cohérent, on peut regarder si par malchance le 'E' est arrivé en seconde position lors de l'analyse de fréquences, sinon on a cassé le code.
- Essayons :

```
SOUVENTPOURSAMUSERLESHOMMESDEQUIPAGEPRENNENTDESALBATROS
VASTESOISEAUXDESMERSQUISUIVENTINDOLENTSCOMPAGNONSDEVOYA
GELENAVIREGLISSANTSURLESGOUFFRESAMERSAPEINELESONTILSDEP
OSESSURLESPLANCHESQUECESROISDELAZURMALADROITSETHONTEUXL
AISSENTPITEUSEMENTLEURSGRANDESAILESBLANCHESCOMMEDESAVIR
ONSTRAINERACOTEDEUXCEVOYAGEURAILECOMMEILESTGAUCHEETVEUL
ELUINAGUERESIBEAUQUILESTCOMIQUEETLAIDLUNAGACESONBECAVEC
UNBRULEGUEULELAUTREMIMEENBOITANTLINFIRMEQUIVOLAITLEPOET
EESTSEMBLABLEAUPRINCEDESNUEESQUIHANTELATEMPETEETSERITDE
LARCHEREXILESURLESOLAUMILIEUDESHUEESSESAILESDEGEANTLEMP
ECHENTDEMARCHER
```

Remise en forme

Souvent, pour s'amuser, les hommes d'équipage
Prennent des albatros, vastes oiseaux des mers,
Qui suivent, indolents compagnons de voyage,
Le navire glissant sur les gouffres amers.

À peine les ont-ils déposés sur les planches,
Que ces rois de l'azur, maladroits et honteux,
Laissent piteusement leurs grandes ailes blanches
Comme des avirons traîner à côté d'eux.

Ce voyageur ailé, comme il est gauche et veule !
Lui, naguère si beau, qu'il est comique et laid !
L'un agace son bec avec un brûle-gueule,
L'autre mime, en boitant, l'infirme qui volait !

Le Poète est semblable au prince des nuées
Qui hante la tempête et se rit de l'archer ;
Exilé sur le sol au milieu des huées,
Ses ailes de géant l'empêchent de marcher.

L'Albatros, de Charles Baudelaire.