



Chiffrement/déchiffrement par substitutiton de lettres au lycée



Auteur : RAYMOND MOCHÉ

L'objet de ce papier est de repérer dans le domaine du chiffrement et déchiffrement des messages, ce qui pourrait être développé en activité d'algorithmique pour le lycée, voir 7. C'est pour cette raison que nous nous limiterons *a priori* au chiffrement par substitution¹ de lettres², qui est le plus facile. C'est un procédé fort ancien qui n'est plus utilisé car les messages codés par substitution ont la réputation de pouvoir être cassés par analyse fréquentielle, voir [11] ou [14] par exemple. Nous verrons ce qu'il en est en réalité, voir 6.

La méthode des fréquences, voir 5.2.2 et 6, n'est pas modélisée. Elle n'a donc aucune justification mathématique, voir 7.2.

Le logiciel de calcul utilisé ici est *scilab* [9]³.

Commandes *scilab* utilisées : commandes basiques, boucles `pour` et `tant que`, `factorial`, `asciimat`, `taille`, `find`, `part`, appel d'une fonction *scilab*, concaténation de deux chaînes de caractères.

Mots-clefs : substitution, permutation, effectif, fréquence.

Table des matières

1	Position du problème	2
2	Principe du codage par substitution de lettres	2
2.1	Généralités	2
2.2	Clef d'un codage par substitution	3
2.3	Clef d'un codage par décalage	3
2.3.1	Généralités	3
2.3.2	Exemple : chiffrement de César	3
3	Codage d'un message par décalage	3
3.1	Codage de César à la main	3
3.2	Codage de César avec <i>scilab</i>	4
3.3	La fonction <code>CoDec</code>	4
4	Codage par substitution de lettres quelconque	5
5	Décodage d'un message par décalage	6
5.1	Décodage d'un décalage à pas connu	6
5.1.1	Décodage à la main	6
5.1.2	La fonction <code>CoDec</code> est une fonction de codage-décodage :	6
5.1.3	Décodage à l'aide de <i>scilab</i>	6
5.2	Décodage d'un décalage à pas inconnu	6

1. ou permutation

2. On dira simplement codage par substitution.

3. En général, on passe facilement d'un logiciel de calcul à un autre.

5.2.1	Décodage par essai de tous les chiffrements par décalage, avec <i>scilab</i>	7
5.2.2	Décodage par la méthode des fréquences, avec <i>scilab</i>	8
6	Décodage par substitution de lettres	11
6.1	Exemple	11
6.2	Commentaires	20
7	Conclusion	20
7.1	Idées d'activités sur le thème du déchiffrement de messages codés	20
7.2	Critique l'utilisation de la méthode des fréquences au lycée	20

1 Position du problème

Voici un texte de Jules César [6] :

Quand ces embarcations furent prêtes, César les fit transporter sur des chariots couplés à une distance de vingt-deux milles de son camp. Il les utilisa pour transporter sur l'autre rive un détachement qui s'empara par surprise d'une hauteur attenante au fleuve. Il se hâta de fortifier la position avant que l'ennemi s'aperçoive de rien, y fait passer une légion et, poussant les travaux des deux côtés à la fois, il rétablit le pont en deux jours. Par ce moyen il permit aux renforts et à ses fourrageurs de le rejoindre en toute sécurité et le ravitaillement des troupes devint plus facile

Imaginons qu'il ait voulu le transmettre à un destinataire qui devrait être capable de le comprendre sans qu'une tierce personne ne le puisse (en cas d'interception par exemple). Pour cela, le message sera codé par César et décodé par son destinataire, qui devra connaître d'avance la clef du décodage. Pratiquement, on néglige les accents, les cédilles, les blancs et la ponctuation si bien que c'est en réalité ce texte

Listing 1 – Message de César

```
M=
quandcesembarcationsfurentpretescesarlesfittransportersurdeschariotscoupl
esaunedistancedevingtdeuxmillesdesoncampillesutilisapourtransportersurla
treriveundetachmentquisemparaparsurprisedunehauteurattenanteaufleuveilse
hatadefortifierlapositionavantquelennemisapercoivederienyfaitpasseruneleg
ionetpoussantlesttravauxdesdeuxcotesalafoisilretablitlepontendeuxjournsparc
emoyenilpermitauxrenfortsetasesfourrageursdelerejoindreentouteseuriteetl
eravitaillementdestroupesdevintplusfacile
—>
```

que l'on devra coder.

2 Principe du codage par substitution de lettres

2.1 Généralités

Le *chiffrement*⁴ *par substitution* [14] est un procédé de codage très simple consiste à effectuer une permutation convenue à l'avance⁵ des lettres de l'alphabet. Il y a évidemment 26! chiffrements de ce type, soit :

4. Codage et chiffrement sont des mots synonymes.
5. avec le destinataire

```
—>factorial(26)
ans =
  4.032914611D+26
—>
```

2.2 Clef d'un codage par substitution

Pour décrire cette permutation, il suffit d'écrire en ligne les 26 lettres de l'alphabet et, en-dessous de chacune d'elle, la lettre qui lui correspond dans la permutation. Cette deuxième ligne peut être appelée *clef du chiffrement*⁶.

Exemple fantaisiste : *Clef du codage azerty*⁷ :

Listing 2 – Clef du codage azerty

```
abcdefghijklmnopqrstuvwxy
azertyuiopqsdghjklmxcvbn
```

Nous verrons plus loin d'autres exemples de clefs de codage par substitution.

2.3 Clef d'un codage par décalage

2.3.1 Généralités

Le codage par décalage, (voir [13]), est un cas particulier de codage par substitution. Plus précisément, j étant un entier donné entre 1 et 25, la première lettre de la clef du chiffrement par décalage de pas j est la lettre de l'alphabet obtenue en décalant la lettre **a** de j pas vers la droite dans l'alphabet, la deuxième est la lettre de l'alphabet obtenue en décalant la lettre **b** de j pas vers la droite, *etc*, jusqu'à **z**⁸.

2.3.2 Exemple : chiffrement de César

C'est le chiffrement par décalage de pas 3, voir [13], dont voici la clef :

Listing 3 – Clef du chiffrement de César

```
abcdefghijklmnopqrstuvwxy
defghijklmnopqrstuvwxyzabc
```

3 Codage d'un message par décalage

Le codage se fait à la main si le message est court. Sinon un petit script *scilab* règlera le problème.

3.1 Codage de César à la main

Soit à chiffrer

```
nostradamus
```

6. Quelquefois, nous appellerons clef l'ensemble des 2 lignes.

7. Clef faisant référence aux claviers français.

8. On a besoin de supposer, à un certain moment, que `abcdefghijklmnopqrstuvwxy` a été prolongé en `abcdefghijklmnopqrstuvwxyzabc`.

Il suffit de se reporter à la clef du codage de César ci-dessus : la première lettre **n** du message (à repérer sur la première ligne du listing 3) doit être remplacée par la lettre qui se trouve juste en dessous, soit **q**, la seconde, **o**, doit de même être remplacée par **r** et ainsi de suite, ce qui donne le message codé suivant :

qrvwudgdpxv

3.2 Codage de César avec *scilab*

Nous allons coder le message du listing 1 à l'aide du chiffrement de César. Ce texte étant assez long, nous programmerons le codage au lieu de l'effectuer à la main et obtiendrons une fonction *scilab* que nous appellerons **CoDec**⁹ qui servira en fait pour tous nos codages et décodages.

3.3 La fonction **CoDec**

Listing 4 – Fonction **CoDec**

```
function MC=CoDec(M,A,C)
a=asciimat(A);
c=asciimat(C);
m=asciimat(M);
t=taille(m);
mC=[];
for j=1:t
    x=c(find(a==m(j)));
    mC=[mC,x];
end
MC=asciimat(mC);
endfunction
```

Commentaires sur le script de CoDec :

Ligne 1 : La fonction **CoDec** a pour entrées 3 chaînes de caractères **M**, **A** et **C**. **M** est le message à coder ; **A** et **C** n'ont pas de doublons et ont la même longueur. **A** comprend tous les caractères utilisés dans **M**. Dans ce papier, au début, **A** est l'alphabet, en lettres minuscules, dans l'ordre lexicographique, **C** est la clef du codage considéré. **CoDec** retourne le message chiffré **MC**.

Ligne 2, 3 et 4 : La commande **asciimat** produit, à partir d'une chaîne de caractères, le vecteur des codes ASCII¹⁰ de ces caractères, et inversement¹¹. Ce détour¹² permet de remplacer un travail sur des chaînes de caractères par un travail sur des vecteurs de nombres entiers.

Ligne 5 : Longueur du message à coder.

Ligne 6 : Initialisation du vecteur **mC** des codes ASCII des caractères du message codé.

Ligne 7 à 10 : Pour chaque caractère du message, sous sa forme de code ASCII, on calcule son rang dans **A** et on identifie le caractère de la clef de même rang (celui qui se trouve juste en-dessous), qui est un nombre entier compris entre 97 et 122 ; enfin, on ajoute ce nombre à la fin de **mC**.

Ligne 11 : Finalement, on met le message codé sous la forme d'une chaîne de caractères notée **MC** en remplaçant les codes ASCII composant **mC** par les caractères correspondants.

9. pour codage-décodage

10. Voir [12]. Les lettres accentuées n'ont pas de code ASCII ainsi que certains signes.

11. Par exemple, si **A**='abcdefghijklmnopqrstuvwxy', **asciimat**(**A**) est le vecteur [97,...,122] tandis que **asciimat**([97, ..., 122])=**A**.

12. Sauf erreur, il est impossible de faire ce travail directement sur des chaînes de caractères avec *scilab* parce que l'on manque d'une commande analogue à **find**.

Listing 5 – Script du codage du message de César

```
M='quandcesembarcationsfurentpretescesarlesfittransportersurdeschariotsco  
uplesaunedistancedevingtdeuxmillesdesoncampillesutilisapourtransportersur  
lautreiveundetachementquisemparaparsurprisedunehauteurattenanreaufleuvei  
lsehatadefortifierlapositionavantquelennemisapercoivederienyfaitpasserune  
legionetpoussantlestravauxdesdeuxcotesalafoisilretablitlepontendeuxjoursp  
arcemoyenilpermitauxrenfortsetasesfourrageursdelerejoindreentoutesecurite  
etleravitaillementdestroupesdevintplusfacile';  
exec('Chemin_de_la_fonction_CoDec.sci',-1);  
A='abcdefghijklmnopqrstuvwxy';  
C='defghijklmnopqrstuvwxyzabc';  
MC=CoDec(M,A,C);  
afficher('MC=');  
afficher(MC);
```

On remarquera ce script comprend le chargement de la fonction `CoDec`. Voici ce qu'il retourne :

Listing 6 – Message codé de César

```
—>exec('Chemin_du_script_ci-dessus',-1)  
MC=  
txdqgfhvhpedufdwlrqvixuhqwsuhwhvfhdvduohvilwwudqvsruwhuvxughvfkdulrwwfrxs  
ohvdxqhgldvdfghghylqjwghxaploohvghvrqfdpsloohvxwlvdsrxuwudqvsruwhuvxu  
dxwuhulyhxqghwdfkhphqwtxlvhpsdudsduvxusulvhgxqhkdxwhxudwwhqduhdxiomyhl  
ovhkdwdghiruwllilhuodsrvlwlrdydwqwtxhohqqhplvdshufrlyhghulhqbidlwsdvvhuxq  
hohjlrqhwsvrvdqwohvwudydxaghvghxafwhvdodirlvlouhwdeolwohsrqwhqghxamrxu  
vsdufhrprbhqloshuplwdxauhqiruwvhdvhwirxuudjhxuvghohuhmrlqguhghqrxwhvhfxu  
lwhhwodudylwdloohphqvwghvwurxshvghylqwsoxvidfloh  
—>
```

Il n'y a rien de neuf.

4 Codage par substitution de lettres quelconque

Se reporter à la section précédente. Il suffit d'utiliser la clef *ad hoc*. On peut utiliser comme clef toute chaîne de 26 signes ayant un code ASCII. Voici un exemple de codage exotique tapé directement dans la console :

Listing 7 – Codage exotique

```
—>A='abcdefghijklmnopqrstuvwxy';  
—>Clefexotique='!#$%&*+,-./:;<=>,@\^A&b2E3)';  
—>M='leshabitsducarnaval';  
—>exec('Chemin_de_la_fonction_CoDec.sci',-1)  
—>MC=CoDec(M,A,Clefexotique);  
—>afficher('MC=');  
MC=  
—>afficher(MC);  
:&\,!#-^%A$!@%-<! :  
—>
```

Ce codage n'est pas plus difficile à casser qu'un codage par substitution ordinaire.

5 Décodage d'un message par décalage

5.1 Décodage d'un décalage à pas connu

5.1.1 Décodage à la main

Reprenons par exemple le message codé

qrvwudgdpvx

On sait qu'il a été codé à l'aide du chiffrement de César. On se reporte donc au listing 3 : la première lettre, soit q , du message codé (à repérer sur la deuxième ligne de la clef) doit être remplacée par la lettre qui se trouve juste au-dessus, soit n , parce que n a donné q dans le codage ; la seconde, soit r , doit de même être remplacée par la lettre qui se trouve juste au-dessus, soit o et ainsi de suite. On obtient ainsi le message décodé, à savoir :

nostradamus

La méthode à la main est longue et ne peut convenir qu'à des messages très courts.

5.1.2 La fonction `CoDec` est une fonction de codage-décodage :

La remarque précédente vaut pour décoder n'importe quel message qui a été codé par substitution de lettres, quelle que soit cette substitution. Par conséquent, en toute généralité, si $MC = \text{CoDec}(M, A, C)$, $M = \text{CoDec}(MC, C, A)$. `CoDec` est donc une fonction de codage-décodage.

5.1.3 Décodage à l'aide de *scilab*

À titre d'exemple, décodons le message codé de César (cf. listing 6) à l'aide du script suivant, qui a été rédigé dans l'éditeur de texte *SciNotes* à la suite du listing 5 :

Listing 8 – suite du listing 5

```
X=CoDec(MC,C,A);  
afficher('X=');  
afficher(X);
```

On obtient :

```
X=  
  quandcesembarcationsfurentpretescesarlesfittransportersurdeschariot  
scouplesaunedistancedevingtdeuxmillesdesoncampillesutilisapourtransporter  
surlautreriveundetachementquisemparaparsurprisedunehauteurattenanteaufleu  
veilsehatedefortifierlapositionavantquelennemisapercoivederienyfaitpasser  
unelegionetpoussantlestravauxdesdeuxcotesalafoisilretablitlepontendeuxjou  
rsparcemoyenilpermitauxrenfortsetasesfourrageursdelerejoindreentoutesecur  
iteetleravitaillementdestroupesdevintplusfacile  
—>
```

On constate que $X=M$: on a retrouvé le message initial.

5.2 Décodage d'un décalage à pas inconnu

Essayons de déchiffrer le message suivant :

```
MC='fytfdszveuvdrizejtfdszveuvtrgzkrzevjhlzjfekgrikzjafpvlogfliuvjtflijvj
cfzkrzevj'
```

sachant seulement qu'il a été codé par décalage ¹³.

5.2.1 Décodage par essai de tous les chiffrements par décalage, avec *scilab*

Comme il n'y a que 25 chiffrements par décalage, on peut les essayer tous à l'aide d'une boucle `pour`. On peut donc utiliser le script suivant :

Listing 10 – Essai de tous les décalages

```
A='abcdefghijklmnopqrstuvwxy';
ADouble=A+A;
MC='fytfdszveuvdrizejtfdszveuvtrgzkrzevjhlzjfekgrikzjafpvlogfliuvjtflijvj
cfzkrzevj';
for j=1:25
    C=part(ADouble, j+1:j+26);
    X=CoDec(MC, C, A);
    afficher(X);
end
```

¹⁴. Ensuite, on charge la fonction `CoDec` et on applique le script, ce qui donne :

```
—>exec('Chemin_de_CoDec.sci', -1)
—>exec('Chemin_du_script', -1)
exsecryudtucqhydisecryudtusqfyjqyduigkyiedjfqhjyizeouknfekhtuisekhiuibey
djydui
dwrdbqxtcstbpgxchrdbqxtcstrpexipxcthfjxhdciepgixhydntjmedjgsthrdjghthadx
cipxcth
cvqcapwsbrsaofwbgqcapwsbrsqodwhowbsgeiwgcbhdofhwgxcmsildcifrsgqcifgsgzcw
bhowbsg
bupbzovraqrznevafpbzovraqrpncvgnvarfdhvfbagnegvfwblrhkcbbheqrfpbhefrfybv
agnvarf
atoaynuqzpqymduzeoaynuqzpqombufmuzqecgueazfbmdfuevakqgjbagdppoeagdeqexau
zfmuzqe
zsnzxmtpyopxlctydnzxmtpyopnlateltypdbftdzyealcetduzjpfiazfcopdnzfcdpdwzt
yelypd
yrmywlsoxnowkbsxcmywlsoxnomkzsdksxocaescyxdzkbdsctyioehzyebnocmyebcvcys
xdksxoc
xqlxvkrnwmnvarwblxvkrnwmnljyrcjrwnbzdrbxwcyjacrbshndgyxdamnbldabnbuxr
wcjrwnb
wpkwujqmvluizqvakwujqmvlmkixqbiqvmaycqawvbxizbqarwgmcfxwczlmakwczamatwq
vbiqvma
vojvtipluklthypuzjvtiplukljhpahpulzxbpzvuawhyapzqvflbewvbyklzjvbyzlsvp
uahpulz
```

13. de pas inconnu

14. Commentaires sur le script « Essai de tous les décalages » :

- à la ligne 2, le signe `+` est le signe de concaténation des chaînes. Par conséquent, `A+A` est la chaîne `'abcdefghijklmnopqrstuvwxyabcdefghijklmnopqrstuvwxy'` ;
- à la ligne 5, on extrait de la chaîne précédente la chaîne de ses éléments du rang `j+1` au rang `j+26` à l'aide de la commande `part`.

```

uniushoktjksgxotyishoktjkigvoztgotkywaoyutzvgxzoypuekadvuaxjkyiuaxykyruo
tztgotky
tmhtrgnjsijrfwnsxhtrgnjsijhfunyfnjsjxvznxtsyufwynxotdjzcutzwijxhtzwxjqtn
syfnjsjx
slgsqfmirhiqevmrwgsqfmirhigetmxemriuwymwsrxtevxmwncisybtsyvhiwgsyvviwpsm
rxemriw
rkfrpelhqghpdulqvfrpelhqghfdslwdlqhvtxlvqrqwsduwlvrbhxasrxughvfrxuvhvorf
qwdlqhv
qjeqodkqpfgoctkpueqodkqpfgecrkvckpguswkuqpvrcvkvulqagwzrqwtfgueqwtugunqk
pvckpgu
pidpncjfoefnbsjotdpncjfoefdbqjubjoftrvjtpouqbsujtkpzfvypvseftdpvstftmpj
oubjof
ohcombiendemarinscombiendecapitainesquisontpartisjoyeuxpourdescoursesloi
ntaines
ngbnlahdmedlzqhmrblahdmedbzohszhmdrpthrnmsozqshrinxdtwontqcdrbntqdrknh
mszhmdr
mfamkzgcblckypglqamkzgcblcayngryglcqsqgmlrnyprgqhmwcvnmspbcqamspqcqjm
glryglc
lezljyfbkabjxofkplzljyfbkabzxmfxkbpnrflkqmxoqfplvbrumlroabpzlropbpilf
kqxfkbp
kdykixejzaiwnejoykixejzaywlepwejaomqeokjplwnpeofkuaqtlkqnzaoykqnoaohke
jpwejao
jcxjhwdziyzhvmdinxjhwdziyzxvkdozdiznlpdnjiokvmodnejtzpskjpmynxjpmnznjgd
iovdizn
ibwigvcyhxygulchmwigvcyhxywujenuchymkocmihnjulncmdisyorjiolxymwiolmymfich
nuchym
havhfubxgwxftkbglvhfubxgwxvtibmtbgxlnblhgmitkmbclhrxnqihnkwxlvhnlxlehb
gmtbgxl
gzugetawfvwesjafkugetawfvwushalsafwkimakgflhsjlakbgqwmphgmjvwkugmjkwdg
aflsafwk
—>

```

On constate que seule la 17^{ème} sortie est compréhensible. C'est donc le message original. Remarquons que *scilab* seul n'est pas capable de retourner le message décodé. Il faut comprendre le français. Il y a intervention humaine. Le message décodé, soit :

```
ohcombiendemarinscombiendecapitainesquisontpartisjoyeuxpourdescourseslointaines
```

peut maintenant être écrit en clair, à la main :

```
Oh! Combien de marins, combien de capitaines qui sont partis joyeux pour des
courses lointaines
```

On en déduit aussi que le pas du décalage qui a servi au chiffrement du message initial était 17.

5.2.2 Décodage par la méthode des fréquences, avec *scilab*

Fréquence des lettres en français, voir ([11])¹⁵

15. On trouve ces fréquences sur beaucoup de sites qui, souvent, n'indiquent pas comment elles ont été calculées. Il y a des exceptions : le site de Bibm@th.net donne des indications assez précises, voir [5]. Le concept de fréquence d'une lettre dans une langue donnée reste quand même assez scabreux.

E	17,76	M	2,72
S	8,23	Q	1,34
A	7,68	V	1,27
N	7,61	G	1,10
T	7,30	F	1,06
I	7,23	B	0,80
R	6,81	H	0,64
U	6,05	X	0,54
L	5,89	Y	0,21
O	5,34	J	0,19
D	3,60	Z	0,07
C	3,32	K	0,00
P	3,24	W	0,00

Ce tableau appelle les remarques suivantes :

- La fréquence du **e**¹⁶ est beaucoup plus grande que celle des autres lettres (0.1776). On peut donc espérer, *si l'on a à déchiffrer un message codé par substitution inconnue*¹⁷, que la lettre la plus fré-

quente du message correspond à la lettre **e** (si l'on tire une lettre au hasard dans un long texte français standard, il y a un peu plus d'une chance sur 6 que ce soit un **e**).

- Cette remarque ne vaut évidemment que si les fréquences des lettres du message codé que l'on a calculées sont significatives (?), c'est à dire (?) si ce message est suffisamment long¹⁸.

- Ces remarques de bon sens valent aussi pour les lettres suivantes plus difficiles à détecter.

- Les totaux des pourcentages des 2¹⁹, 5²⁰ et 10²¹ lettres les plus fréquentes de la langue française sont respectivement égaux à 25,99%, 48,52% et 79,89%, ce qui veut dire que si l'on tire une lettre au hasard dans un long texte en français, il y a à peu près une chance sur 4, une chance sur 2 et 4 chances sur 5 de tirer un **e**, un **e** ou un **s**, une lettre de **e,s,a,n,t** ou une lettre de **e,s,a,n,t,i,r,u,l,o**.

Exemple qui marche On se propose de déchiffrer le message suivant, codé par décalage de pas inconnu :

M= ' tsutzafnyjshtwjjwjrfrwvzjwztzywjhjyyjrfxxjifwwnafsyxvznatzqfnjsyjsywjwifswxqfanqqjvzjqvzjxlwtzujxijufwynhzqnjwxvznxjrgqfnjsyjsjywjxtwynx ' ;

Pour cela, nous allons rechercher la lettre de ce message dont la fréquence est la plus élevée. En fait, on va utiliser des effectifs au lieu de fréquences. On calculera les effectifs des différentes lettres du message à l'aide de la fonction **Effectifs** suivante :

Listing 11 – Effectifs

```
function lEf=Effectifs (M)
m=asciimat (M);
lEf = [];
while taille (m)>0
d=m($);
x=find (m==d);
tx=taille (x);
lEf=[lEf , [d ; tx ]];
m(x) = [];
end
endfunction
```

Commentaires sur le script « Effectifs » :

- M est une chaîne de lettres.

16. comprenant les **e** accentués
17. en particulier par décalage de pas inconnu
18. Cette remarque communément admise n'a aucun fondement mathématique.
19. **e,s**
20. **e,s,a,n,t**
21. **e,s,a,n,t,i,r,u,l,o**

- **m** est la chaîne des codes ASCII de ces lettres.
- **lEf** initialise le tableau des différentes lettres de **M** (1^{ère} ligne) et de leurs effectifs (2^{ème} ligne).
- **d** est le dernier élément de **m**.
- **x** est le vecteur des rangs dans **m** où l'on trouve **x**.
- **tx** est l'effectif de **d** dans **m**.
- La commande **m(x)=[]** efface la lettre que l'on vient de traiter.

Ce qui donne :

```

—>clear
—>exec('Chemin_de_CoDec.sci', -1)
—>M='tsutzafnyjshtwjjrfwvzjwtywjhjyyjrfxxjifwwnafsyxvznatzqfnjsyjsywj
wifxqfanqqjvzjqzjxlwtzujxijufwynhzqjwvxvnxjrgqfnjsyjsywjxtwynx';
—>exec('Chemin_de_Effectifs.sci', -1)
—>lEf=Effectifs(M); afficher(lEf);
      column 1 to 12
      120.   110.   121.   119.   116.   106.   115.   102.   113.
      10.    10.    11.    14.     7.    22.    8.    10.    7.

      column 13 to 18
      103.   114.   122.   118.   104.   117.   105.   108.   97.
      1.     3.    10.    5.     3.    3.    3.    1.    4.
—>

```

On constate qu'il y a 18 lettres différentes dans le message **M** et que l'une d'elles a un effectif nettement plus grand que les 17 autres. C'est la lettre de code ASCII égal à 106, soit

```

—>ascii(106)
ans =
j
—>

```

Cela signifie que dans le décalage du codage inconnu, la lettre **e** a été remplacée par **j**²², autrement dit, le pas de ce décalage est 5. Admettant cette hypothèse, on peut décoder le message **M** comme précédemment. Si l'on obtient un texte en compréhensible en français, on conclura que c'est bien le message recherché²³.

```

—>clear
—>M='tsutzafnyjshtwjjrfwvzjwtywjhjyyjrfxxjifwwnafsyxvznatzqfnjsyjsywj
ifxqfanqqjvzjqzjxlwtzujxijufwynhzqjwvxvnxjrgqfnjsyjsywjxtwynx';
—>exec('Chemin_de_Effectifs.sci', -1)
—>lEf=Effectifs(M); afficher(lEf);
      column 1 to 12
      120.   110.   121.   119.   116.   106.   115.   102.   113.
      10.    10.    11.    14.     7.    22.    8.    10.    7.

      column 13 to 18
      103.   114.   122.   118.   104.   117.   105.   108.   97.
      1.     3.    10.    5.     3.    3.    3.    1.    4.
—>A='abcdefghijklmnopqrstuvwxy';

```

22. Ce n'est qu'une hypothèse, assez vraisemblable. Ce n'est pas une certitude.

23. en espérant qu'il n'y a qu'un seul message compréhensible!

```

—>C=' fghijklmnopqrstuvwxyzabcde ' ;
—>exec( 'Chemin_de_CoDec.sci ', -1)
—>Message=CoDec(M,C,A); afficher( Message );
on pouvait en corer remarquer out recette masse d'arrivants qui voulaient entrer dans
la ville quelques groupes de particuliers qui semblaient en etre sortis
—>

```

Commentaires :

Message est compréhensible donc C est bien la clef du chiffrement par décalage utilisé.

Exemples qui ne marchent pas Tout message dont la fréquence de la lettre qui code le e n'est pas la plus élevée conduira à une erreur par la méthode précédente. On conclura quand même qu'en gros, c'est une méthode efficace.

6 Décodage par substitution de lettres

Cette section repose uniquement sur la méthode des fréquences.

6.1 Exemple

On désire maintenant déchiffrer le message codé M0 suivant :

```

ostlmsthswlptwfttwkghttfatmktktmtfwhgwkwttdollogflhamoastetlmwfmngweitamgwm
hwoljwostlmetofmwktfgoktrtpwrgtmpgwtrwlvghigftrtlyawsmtrlrgfmosftrtxkaomhala
xgokztlgofrwdgoffhalawmafjnwtladaomkoltrtlovsafuwtlwfamgwmhgwkegddwfojwtkax
xteltlegsstuwtlkwlltlgwadtkoaoflosawkartjwgoelgeewhtkhwoljwltgfhkgukaddtrtmkaxa
osegdhmasozoltrtfgdzktwltlvhtkotfetlaoflostptwftalmkgfawmtltkaegfftemawftmazst
mmthgwkegsstemtkrtlrgffttlksamoxtlasahiblogsguotiwdaoftetltmwrtlltkxokgfmfgma
ddtfmartyofokrtyaegfmltkteoltmasgfumtkdtsltztlgofflasodtfmaoklrltalmkgfawmtls
gklrtlxgslrtsgfuwtrwktmtsetswojwohgwkkgapofrktaklwftawmktdollogfegflolmtkaam
tlmtksamitgkotrtsaukaxomamogfltsghsajwtsstsaukaxomtawftofyswtfetlwkstegwstdtfm
rwmtdhllhgwkdltlwkstkstmdhlaxtefftvaemomwrmtmwfmlmazosomtoftuasttwftigksguta
mgdojwtfgwxtsstlkaoflmasstastvmtkotwkrtsalmamogfgkzomastetmmtvhtkotfethk
dtmmkartlbfekgfoltkaxtefftswlukaftrhkteologfstllblmtdtlrthglomogffdtfmhaklamts
sont

```

On sait seulement qu'il a été codé par une substitution dont la clef est inconnue. Ce problème est beaucoup plus difficile que le cas particulier d'un décalage de pas inconnu. En effet, les clefs de substitution sont tellement nombreuses que l'on ne peut pas envisager de les essayer toutes, comme on l'a fait en 5.2.2. Reste la méthode de décryptage basée sur les fréquences des lettres du message codé. Cette méthode des fréquences est réputée assez facile (cf. [14] par exemple). En fait, ce n'est pas vrai. Ça peut être très long. C'est aussi très désagréable, comme on va le voir dans l'exemple entièrement traité ci-dessous. Nous allons successivement :

- calculer la fréquence des différents caractères de M0,
- ranger ces caractères par ordre de fréquences décroissantes, ce qui conduira à L1 puis à Cideal ci-dessous²⁴,
- remplacer dans M0 chaque caractère de Cideal par le caractère de même rang de la chaîne Aideal='esantirulodcpmqvgfbhxyjzkw'.

24. Cideal est la chaîne de toutes les lettres minuscules de l'alphabet rangées dans l'ordre de leurs fréquences dans M0 décroissantes, les lettres absentes étant considérées comme présentes avec la fréquence nulle.

²⁵. Identifier ainsi chaque caractère de MO avec le caractère de même rang²⁶ de Aideal fournirait, si cela marchait, une méthode de décryptage automatique (entièrement calculable sans intervention du déchiffreur). Mais cela ne marche pas comme on va le voir. Nous devons décoder les lettres presque une par une !

Ces scripts successifs²⁷ sont des blocs de commandes rédigés au fur et à mesure dans Scinotes où ils se suivent à la queue leu leu. Le script complet s'appelle Commandes.sce. Il utilise les fonctions CoDec et Resumer qui doivent être chargées préalablement dans la console de Scilab. La fonction Resumer prolonge la fonction Effectifs en rangeant les lettres du message considéré par ordre de fréquences décroissantes²⁸ :

Listing 12 – Fonction Resumer

```
//Ch est une chaine de lettres donnee. La fonction renvoie le vecteur des
//codes ASCII des lettres figurant dans Ch rangees dans l'ordre des
//frequences decroissantes (ligne1) et ces frequences (ligne2).
function res=Resumer(Ch)
    ch=asciimat(Ch); //Vecteur des codes ASCII des lettres de Ch.
    t=taille(ch);
    Resu=[]; //Initialisation de la matrice dont la premiere ligne sera le
    //vecteur des elements differents de ch (comptes a partir du dernier)
    //et dont la seconde sera la suite de leurs effectifs.
    chp=ch;
    while taille(chp)>0
        der=chp($); //Code ASCII de la derniere lettre de Ch.
        x=find(chp==der); //Rangs des apparitions de der dans chp.
        ef=taille(x);
        Resu=[Resu, [der; ef]];
        chp(x)=[]; //Effacement de ce que l'on vient de traiter.
    end
    //On va maintenant ranger les codes des lettres figurant dans Ch par
    //ordre de frequences decroissantes.
    res=[]; //Initialisation du vecteur des codes des lettres de Ch
    //rangees dans l'ordre decroissant.
    l1=Resu(1,:); //Codes ASCII des lettres figurant dans Ch, rangees.
    l2=Resu(2,:); //Effectifs de ces lettres.
    format(6);
    while taille(l2)>0
        m=max(l2);
        k=max(find(l2==m)); //On choisit une lettre d'effectif maximum
        //s'il y en a plusieurs.
        res=[res, [l1(k); l2(k)/t]];
        l1(k)=[];
        l2(k)=[];
    end
endfunction
```

Nous pouvons commencer à dérouler le script Commandes.sce qui fournira le décodage recherché :

25. chaîne des lettres minuscules de l'alphabet rangées par ordre de fréquences décroissantes, voir [11]

26. rang lu dans Aideal

27. suivis de commentaires

28. Comme on le constate souvent, ce script commenté est plus indigeste que si l'on avait omis les commentaires.

```

clear
Alphabet='abcdefghijklmnopqrstuvwxy';
M0='ostlmsthswlptwfttwkghttfatmktktmtfwhgwkwtfdollogflhamoas..
tetlmwfmngweitamgwmhwoljwostlmetofmwkftgoktrtpwrgtmpgwtrwlvag..
higftrtlyaewsmtlrgfmosftrtxkaomhalaxgokztlgofrwdgoflhalawmaf..
mjwtladaomkoltrtlovsafuwtlwfamgwmhgwkegddwfojwtkaxtellegsstu..
wtlkwlltlgwadtkoeaoflosawkartjwolgeewhtkhwoljwtlgfhkgukaddtrt..
mkaxaosegdhmazosoltrtfgdzktwltlvhtkotfetlaoflostptwftalmkgfa..
wmtltkaegfftemtawftmazstmmthgwkegsstemtkrtlrgfftlktsamoxtlasa..
hiblogsguotiwdaoftetltmwrlltkxokgfmfgmaddtfmartyofokrtyaegfmk..
tlhktoelttmasgfumtkdstlztlgoflasodtfmaoklrtlalmkgfawmtlsgklr..
tlxgslrtsqfuwtrwktmtsetswojwohgwkkapgofrktdaklwftawmktdollogf..
egflolmtkaamtltmksamitgkotrtsaukaxomamogfltsafsajwtsstsaukaxom..
tawftofyswtfetlwkstegwstdtfmrwmtdhlhgwkdtlwtkkstmdhlaxtefft..
aemomwrttmwftlmazosomtoftuasttwftigksgutamgdojwtfgwxtsstlkaof..
lmasstastvmtkotwkrtsalmamogfgkzomastetmmttvhtkotfethtkdtmmkar..
tlbfeikgfoltkaxtefthswlukaftrhkteologfstllblmtdtlrthglomogfft..
dtfmhaklamtssomt';
exec('Chemin_de_la_fonction_Resumer.sci', -1)
r1=Resumer(M0);
//afficher('r1=');//affichage inutile.
//afficher(r1);//idem
l1=r1(1,:);//Vecteur des codes ASCII des lettres de M0 rangees par
//ordre de frequences décroissantes.
L1=asciimat(l1);
afficher('L1=');
afficher(L1);
f1=r1(2,:);//Vecteur des frequences correspondantes.
afficher('f1=');
afficher(f1);

```

ce qui donne :

Listing 14 – Résumé de M0

```

—>clear
—>exec('Chemin_de_Commandes.sce', -1)
L1=
tlamfowkgserhdxujzivpyb
f1=
      column 1 to 10
0.178    0.086    0.077    0.076    0.071    0.071    0.070    0.066
0.064    0.057
      column 11 to 20
0.032    0.030    0.029    0.027    0.013    0.012    0.009    0.007
0.007    0.006
      column 21 to 23
0.005    0.004    0.003
—>

```

Ces résultats montrent que le message codé M0 utilise seulement 23 lettres de l'alphabet dont le rangement par ordre de fréquences décroissantes se lit sur la première ligne l1 de r1, si on se

contente des codes ASCII de ces lettres. Elles-mêmes forment la chaîne L1, plus lisible.

Ci-dessous, le déchiffreur a complété L1 à la main avec les 3 lettres manquantes **c,n,q**, ce qui a donné la chaîne **Cideal** ²⁹ appelée ainsi parce que la situation idéale serait celle où la lettre la plus fréquente de M0, soit **t**, proviendrait de la lettre la plus fréquente de l'alphabet, soit **e** ³⁰, et de même pour les lettres suivantes, autrement dit, idéalement, on mettrait en correspondance les chaînes **Aideal** et **Cideal** ³¹. *Nous aurions ainsi un algorithme qui décode automatiquement les messages codés par substitution de lettres.* Évidemment, ça ne marche pas ³², ce que nous allons constater sur notre exemple :

Listing 15 – Suite de **Commandes.sce**

```
Aideal='esantirulodcpmqvgfbhxyjzkw';
Cideal=L1+'cnq';// 'cnq' trouve a la main. Concatenation de chaines.
exec('Chemin_de_la_fonction_CoDec.sci', -1)
Mideal=CoDec(M0, Cideal, Aideal);
afficher('Mideal=');
afficher(Mideal);
```

On obtient **Mideal** qui est incompréhensible et ne peut être le message original :

Listing 16 – Cas idéal et désespéré à la fois

```
Mideal=
ioesnoeporsxerteerulpeetaenuenetrplrurtemissiltspaniaoedesnrtnlrdbeanl
rnprisgrioesndeitnruetliuecexrclenxlrecrsahlpbltecesyadronescltniotecequ
ainpasaqliufeslitcrmlitspasarnatngresamainuisecehsihoatvresrtanlrnplrudlm
mrtigreuaqedsesdlooevresursseslrameuidaitsioaruacegrlislddrpeuprisgreslt
pulvuammecenuaqaiodlmpnafioisecetlmfuersesehpeuietdesaitsioexerteasnulta
rneseuadlttedneartenafoenneplrudloeedneucescltteesueoaniquesaopbjsilolvi
ebrmaitedesenrcesseuqiultntlnammetnaceyitiuceyadltnuespuediseenaoltvneu
meoesfslitsaoimetnauiescesasnultarnesoluscesqlosceoltvrecrueeneodeorigr
iplruuaxlitcuemausrtearnuemissiltdltsisneuaanesneuoanbeluieceoavuaqinani
ltseoltoagreooeoavuaqinearteityoretdesruoeddroemetncrnempsplruesrueueo
nempsaqedrteehadninrceenrtesnafioineitevaoeertebluolveanlmigretlrqeoese
uaitснаooeeaoehneuieruceoasnaniltlufinaoedenneehpeuietdepeumennuacesjtd
bultiseuaqedrteporsvuatcepuedisiltoessjsnemesceplsinilttemetnpausaneooin
e
```

Il faut donc se résoudre à procéder plus systématiquement.

- On a déjà dit que l'on peut raisonnablement supposer que **e** → **t**.
- De même, on peut considérer que **s** → **l** est à peu près sûr.
- Ensuite, nous ferons le pari très risqué que **a** → **a**. C'est risqué parce qu'en fait les fréquences de la troisième à la septième lettres ³³ dans M0 sont assez voisines. On parie que **a** → **a**, mais ça pourrait être **a** → **m** ou **a** → **f** ou **a** → **o** ou **a** → **w** ou pis. Le risque de perte de temps est donc grand.
- Pour améliorer la lisibilité des résultats, on écrira en majuscules les lettres considérées comme déchiffrées.
- On fait donc **e** → **T**, **s** → **L**, **a** → **A**, ce que traduit la clef **C1** ci-dessous, fabriquée à la main à partir de **Alphabet**.

29. On aurait pu écrire un script *ad hoc* pour calculer **Cideal** automatiquement.

30. ce que nous notons ci-dessous **e** → **t**

31. On rappelle que **Aideal** est l'alphabet rangé dans l'ordre des fréquences décroissantes.

32. ça se saurait !

33. rangées suivant les fréquences décroissantes

- Le message obtenu³⁴ est noté M1.

Listing 17 – Suite de Commandes.sce

```
C1= ' AbcdefghijkSmnopqrsEuvwxyz ' ;
M1=CoDec(M0, Alphabet , C1);
afficher ( 'M1=' );
afficher (M1);
```

Listing 18 – M1

```
M1=
osESmsEhswSpEwfEEwkgheEefAEmkEkEmEfwhgwkwfEdoSSogfShAmoAsEeESmwfmgweiEAmg
wmhwoSjwosESmeEofmwkEfgokErEpwrgEmpgwErwSAvghigfErESyAewsmESrgfmosfErExk
AomhASAxgokzESgofrwdgofShASAwmAfmjwESAdAomkoSErESovsAfuwESwfAmgwmhgwkegd
dwfojwEkAxEeSESegssEuwESkwSSESgwAdEkoeAofSosAwkArEjwgoSgeewhEkhwoSjwESgf
hkgukAddErEmkAxAosegdhmAzosoSErEfgdzkEwSESEvhEkoEfeESAofSosEpEwfEASmkgfA
wmESEkAegffEemEAwfEmAzsEmmEhgwkessEemEkrESrgffEESkEsAmoxESAsAhibSogsguo
EiwdAofEeESEmwrESSEkxokgfmfgmAddEfmarEyofokrEyAegfmkEShkEeoSEEmAsgfumEkd
EsESzESgofSAsodEfmaokESrESASmkgfAwmESsgkSrESxgsSrEsgfuwErwkeEEmEseEswojwo
hgwkApgofrkEdAkSwfEAwmkEdoSSogfegfSoSmEkAAmESmEksAmiEgkoErEsAukAxomAmog
fSEsgfsAjwEssEsAukAxomEAwfEofyswEfeESwksEegwsEdEfmrwmEdhShgwkDESwkEksEmE
dhSAxEewfEEvAemomwrEEmwfESmAzosomEofEuAsEEwfEigksguEAmgdojwEfgwxEssESEkA
ofSmAssEEAsEvmEkoEwkrEsASmAmogfgkzomAsEeEmmEEvhEkoEfeEhEkdEmmkArESbfeik
gfoSEkAxEewfEhswSukAfrEhkEeoSogfsESSbSmEdESrEhgSomogffEdEfmaAkSAMessomE
```

On n’y voit rien de réhibitoire. Essayons maintenant de débusquer la lettre qui donnera N, qui est la quatrième lettre la plus fréquente de l’alphabet. En se guidant avec Cideal, on commence par tester $m \rightarrow N$, puis si nécessaire, on essaiera $f \rightarrow N$, $o \rightarrow N$, $w \rightarrow N$, etc.

Listing 19 – Suite de Commandes.sce

```
//Essai de a->A et de m->N.
C2= ' AbcdefghijkSNnopqrsEuvwxyz ' ;
M2=CoDec(M0, Alphabet , C2);
afficher ( 'M2=' );
afficher (M2);
```

Listing 20 – Cul de sac

```
M2=
osESNsEhswSpEwfEEwkgheEefAENkEkENEFwhgwkwfEdoSSogfShANoAsEeESNwfNgweiEANg
wNhwoSjwosESNeEofNwkEfgokErEpwrgENpgwErwSAvghigfErESyAewsNESrgfNosfErExk
AoNhASAxgokzESgofrwdgofShASAwNAfnjwESAdAoNkoSErESovsAfuwESwfANgwnhgwkegd
dwfojwEkAxEeSESegssEuwESkwSSESgwAdEkoeAofSosAwkArEjwgoSgeewhEkhwoSjwESgf
hkgukAddErENkAxAosegdhNAzosoSErEfgdzkEwSESEvhEkoEfeESAofSosEpEwfEASNkgfA
wNESEkAegffEeNEAwfENAzsENNEhgwkessEeNEkrESrgffEESkEsANoxESAsAhibSogsguo
EiwdAofEeESENwrESSEkxokgfNfgNAddEfNArEyofokrEyAegfNkEShkEeoSEENAsgfuNEkd
EsESzESgofSAsodEfNAokESrESASNkgfAwmNESsgkSrESxgsSrEsgfuwErwkeEENEseEswojwo
hgwkApgofrkEdAkSwfEAwnkEdoSSogfegfSoSNEkAANESNEksANiEgkoErEsAukAxoNANog
fSEsgfsAjwEssEsAukAxoNEAwfEofyswEfeESwksEegwsEdEfNrwNEdhShgwkDESwkEksENE
dhSAxEewfEEvAeNoNwrEENwfESNAzosoNEofEuAsEEwfEigksguEANgdojwEfgwxEssESEkA
```

34. sur la voie du décodage ?

```
ofSNAssEEAsEvNEkoEwkrEsASNANogfgkzoNAsEeENNEEvhEkoEfeEhEkdENNkArESbfeikg
foSEkAxEewfEhswSukAfrEhkEeoSogfsESSbSNEdESrEhgSoNogffEdEfNhAkSANEssoNE
```

Nous ne voyons aucun groupement de lettres majuscules qui fait penser à un mot, mais plutôt des groupements suspects. Nous rejetterons donc la tentative m → N. Testons à sa place f → N, ce qui va conduire à C3 et M3.

Listing 21 – Suite de Commandes .sce

```
//Essai de a->A et de f->N.
C3=' AbcdeNghijkSmnopqrsEuvwxyz ' ;
M3=CoDec(M0, Alphabet , C3) ;
afficher ( 'M3=' ) ;
afficher (M3) ;
```

ce qui donne

Listing 22 – M3

```
M3=
osESmsEhswSpEwNEEwkghEENAEmkEkEmENwhgwkWNEdoSSogNShAmoAsEeESmwNmgweiEAmg
wmhwoSjwosESmeEoNmwkENgokErEpwrgEmpgwErwSAvghigNErESyAewsmESrgNmosNErExkA
omhASAxgokzESgoNrwgdoNShASAwmANmjwESAdAomkoSErESovsANuwESwNAmgwmhgwkgedd
wNojwEkAxEeSESegssEuwESkwSSEsgwAdEkoeAoNSosAwkArEjwgoSgeewhEkhwoSjwESgNhk
gukAddErEmkAxAosegdhmAzosoSErENgdzkEwSESEvhEkoENeESAoNSosEpEwNEASmkgNAwm
ESEkAegNNEemEAwNEmAzsEmmEhgwkegssEemEkRESrgNNEESkEsAmoxESAsAhibSogsguoEiw
dAoNEeESEmwrESSEkxokgNmNgmAddENmArEyoNokrEyAegNmKEShkEeoSEEmAsgNumEkdEsE
SzESgoNSAsodENmAokESrESASmkgNAwmESsgkSrESxgsSrEsgNuWErwKEEmEseEswojwohgwk
kApgoNrkEdAkSwNEAwmkEdoSSogNegNSoSmEkAAmESmEksAmiEgkoErEsAukAxomAmogNSEsg
NsAjjwEssEsAukAxomEAwNEoNyswENEESwksEegwsEdENmrwmEdhShgwkdESwkEksEmEdhSAxE
ewNEEvAemomwrEEmwNEMSmAzosomEoNEuAsEEwNEigksguEAmgdojwENgwxEssESEkAoNSmAss
EEAsEvmEkoEwkrEsASmAmogNgkzomAsEeEmmEEvhEkoENeEhEkdEmmkArESbNeikgNoSEkAxE
ewNEhswSukANrEhkEeoSogNsESSbSmEdESrEhgSomogNNEdENmhAkSAMessomE
```

Dans M3, la séquence ESrgNNEES invite à tenter r → D et g → O. On introduit ainsi C4 et M4 :

Listing 23 – Suite de Commandes .sce

```
C4=' AbcdeNOhijkSmnopqDsEuvwxyz ' ;
M4=CoDec(M0, Alphabet , C4) ;
afficher ( 'M4=' ) ;
afficher (M4) ;
```

ce qui donne :

Listing 24 – M4

```
M4=
osESmsEhswSpEwNEEwkOhEENAEmkEkEmENwhOwkWNEdoSSoONShAmoAsEeESmwNmOweiEAmOw
mhwoSjwosESmeEoNmwkENookEDEpwDOEmpOwEDwSAvOhiONEDESyAewsmESDONmosNEDEExkAo
mhASAxOokzESOoNDwdOoNShASAwmANmjwESAdAomkoSEDESovsANuwESwNAmOwmhOwkeOddwN
ojwEkAxEeSESeOssEuwESkwSSESOWAdEkoeAoNSosAwkADEjwOoSoeewhEkhwoSjwESONhkOu
kAddEDEmKAxAoseOdhmAzosoSEDENodzKewSESEvhEkoENeESAoNSosEpEwNEASmkONAwmESE
kAeONNEemEAwNEmAzsEmmEhOwkeOssEemEkDESdonNEESkEsAmoxESAsAhibSoOsOuoEiwdAo
NEeESEmWDESSEkxokONmNOMAddENmADEyoNokDEyAeONmkEShkEeoSEEmAsONumEkdEsESzES
OoNSAsodENmAokESDESASmkONAwmESsOkSDESxOsSDESONuwEDwKEEmEseEswojwohOwkKApO
```



```
oNDkEdAkSwNEAwmkEdoSSoONeONSoSmEkAAmESmEksAmiEOkoEDEsAukAxomAmoONSEsONsAj
wEssEsAukAxomEAwNEoNyswENeESwksEeOwsEdENmDwmEdhShOwkDESwkEksEmEdhSAxEewNE
EvAemomwDEEmwNESmAzosomEoNEuAsEEwNEiOksOuEAmOdojwENowxEssESEkAoNSmAssEEAs
EvmEkoEwkDEsASmAmoONOkzomAsEeEmmEEvhEkoENeEhEkdEmmkADESbNeikONoSEkAxEewNE
hswSukANDEhkEeoSoONsESSbSmEdESDEhOSomoONNEdENmhAkSAmEssomE
```

Si nous sommes sur la bonne voie, nous avons déjà décodé 6 lettres, à savoir E, S, A, N, O, D. Recherchons d'où proviennent les lettres t et i qui sont les lettres les plus fréquentes de l'alphabet dans les lettres encore manquantes. Essayons m -> T (en tenant compte de Cideal)

Listing 25 – Suite de Commandes.sce

```
C5= ' AbcdeNOhijkSTnopqDsEuvwxyz ' ;
M5=CoDec(M0, Alphabet , C5) ;
afficher ( 'M5=' ) ;
afficher (M5) ;
```

ce qui donne M5 :

Listing 26 – M5

```
M5=
osESTsEhswSpEwNEEwkOhEENAETkEkETENwhOwkWNEdoSSoONShAToAsEeESTwNTOWeiEATOW
ThwoSjwosESTeEoNTwkENookEDEpwDOETpOwEDwSAvOhiONEDESyAewsTESDONTosNEDEExkAo
ThASAxOokzESOoNDwdOoNShASAwTANTjwESAdAoTkoSEDESovsANuwESwNATOWThOwkeOddwN
ojwEkAxEeSESeOssEuWESkwSSESOWAdEkoeAoNSosAwkADEjwOoSoeewhEkhwoSjwESONhkOu
kAddEDETkAxAoseOdhTAzosoSEDENodzEwSESEvhEkoENeESAoNSosEpEwNEASTkONAwTESE
kAeONNEeTEAwNETAzsETTEhOwkeOssEeTEkDESDONNEESkEsAToxESAsAhibSoOsOuoEiwDAo
NEeESETwDESSEkxokONTNOTAddENTADEyoNokDEyAeONTkESHkEeoSEETAsONuTEkdEsESzES
OoNSAsodENTAokESDESASTkONAwTESsOkSDESxOsSDESONuwEDwkEETEseEswojwohOwkkApO
oNDkEdAkSwNEAwTkEdoSSoONeONSoSTEkAAESTEksATiEOkoEDEsAukAxoTAToONSEsONsAj
wEssEsAukAxoTEAwNEoNyswENeESwksEeOwsEdENTDwTEdhShOwkDESwkEksETEdhSAxEewNE
EvAeToTwDEETwNESTAzosoTEoNEuAsEEwNEiOksOuEATOdojwENowxEssESEkAoNSTAssEEAs
EvTEkoEwkDEsASTAToONOkzoTAsEeETTEEvhEkoENeEhEkdETTkADESbNeikONoSEkAxEewNE
hswSukANDEhkEeoSoONsESSbSTEdESDEhOSoToONNEdENThAkSATEssoTE
```

Interrompons la recherche du i car la séquence ONTNOTAddENTADE invite à faire d -> M.

Listing 27 – Suite de Commandes.sce

```
C6= ' AbcMeNOhijkSTnopqDsEuvwxyz ' ;
M6=CoDec(M0, Alphabet , C6) ;
afficher ( 'M6=' ) ;
afficher (M6) ;
```

Listing 28 – M6

```
M6=
osESTsEhswSpEwNEEwkOhEENAETkEkETENwhOwkWNEMoSSoONShAToAsEeESTwNTOWeiEATOW
ThwoSjwosESTeEoNTwkENookEDEpwDOETpOwEDwSAvOhiONEDESyAewsTESDONTosNEDEExkAo
ThASAxOokzESOoNDwMOoNShASAwTANTjwESAMAAoTkoSEDESovsANuwESwNATOWThOwkeOMMw
NojwEkAxEeSESeOssEuWESkwSSESOWAMEkoeAoNSosAwkADEjwOoSoeewhEkhwoSjwESONhkO
ukAMMEDETkAxAoseOMhTAzosoSEDENOMzkEwSESEvhEkoENeESAoNSosEpEwNEASTkONAwTES
EkAeONNEeTEAwNETAzsETTEhOwkeOssEeTEkDESDONNEESkEsAToxESAsAhibSoOsOuoEiwMA
oNEeESETwDESSEkxokONTNOTAMMENTADEyoNokDEyAeONTkESHkEeoSEETAsONuTEkMEsESzE
SOoNSAsomentAokESDESASTkONAwTESsOkSDESxOsSDESONuwEDwkEETEseEswojwohOwkkAp
```

```
OoNDkEMAkSwNEAwTkEMoSSoONeONSOSTEkAATESTEkSAtiEOkoEDEsAukAxoTAToONSEsONs
AjwEssEsAukAxoTEAwNEoNyswENEESwksEeOwsEMENTDwTEMhShOwkMESwkEksETEMhSAxEew
NEEvAeToTwDEETwNESTAzosoTEoNEuAsEEwNEiOksOuEATOMojwENowxEssESEkAoNSTAssEE
AsEvTEkoEwkDEsASTAToONOkzoTAsEeETTEEvhEkoENeEhEkMETTtKADESbNeikONoSEkAxEew
NEhswSukANDEhkEeoSoONsESSbSTEMESDEhOSoToONNEMENThAkSATEssoTE
```

Nous avons maintenant décodé 8 lettres, c'est à peu près sûr. Les séquences SbSTEMES et SATEssoTE invitent à essayer b -> Y, s -> L et o -> i.

Listing 29 – Suite de Commandes.sce

```
C7= 'AYcMeNOhijkSTnIpqDLEuvwxyz';
M7=CoDec(M0, Alphabet, C7);
afficher('M7=');
afficher(M7);
```

On obtient ainsi :

Listing 30 – M7

```
M7=
ILESTLEhLwSpEwNEEwkOhEENAETkEkETENwhOwkNEMISSIONShATIALEeESTwNTOWeiEATOW
ThwISjwILESTeINTwkENOIkEDEpwDOETpOwEDwSAvOhiONEDESyAewLTESDONTILNEDEExkAI
ThASAxOIkzESOINDwMOINShASAwTANTjwESAMAITkISEDESIVLANuwESwNATowThOwkeOMMw
NIjwEkAxEeSESeOLLEuwESkwSSESOWAMEkIeAINSILAwkADEjwOISOeewhEkhwISjwESONhkO
ukAMMEDEtKAXAILeOMhTAzILISEDENOMzkEwSESEvhEkIENeESAINSILEpEwNEASTkONAwTES
EkAeONNEeTEAwNETAzLETTEhOwkeOLLEeTEkDESDONNEESkELATIxEsALAhIYSIOLOuIEiwMA
INEeESETwDESSEkxIkONTNOTAMMENTADEyINIRDEyAeONTkEShkEeISEETALONuTEkMELESzE
SOINSALIMENTAIKESDESASTkONAwTESLOkSDESxOLSDELONuwEDwkEETELeELwIjwIhOwkAp
OINDkEMAkSwNEAwTkEMISSIONeONSISTEkAATESTEkLATiEOkIEDELAukAxITATIONSELONLA
jwELLELAukAxITEAwNEINyLwENeESwkLEeOwLEMENTDwTEMhShOwkMESwkEkLETEMhSAxEewN
EEvAeTITwDEETwNESTAzILITEINEuALEEwNEiOkLOuEATOMIjwENowxEssESEkAINSTALLLEE
LEvTEkIEwkDELASTATIONOkzITALEeETTEEvhEkIENeEhEkMETTtKADESyNeikONISEkAxEewN
EhLwSukANDEhkEeISIONLESSYSTEMESDEhOSITIONNEMENThAkSATELLITE
```

La séquence SYSTEMESDEhOSITIONNEMENThAkSATELLITE invite à essayer h -> P, k -> R; la séquence LEhLwS invite ensuite à tester w->U.

Listing 31 – Suite de Commandes.sce

```
C8= 'AYcMeNOpijRSTnIpqDLEuvUxyz';
M8=CoDec(M0, Alphabet, C8);
afficher('M8=');
afficher(M8);
```

Listing 32 – M8

```
M8=
ILESTLEPLUSpEUNEEUROPEENAETRERETENUPOURUNEMISSIONSPATIALEeESTUNTOUeiEATOU
TPUISjUILESTeINTURENOIREDEpUDOETpOUEDUSAvoPiONEDESyAewULTESDONTILNEDEExRAI
TPASAxOIRzESOINDUMOINSPASAUTANTjUESAMAITRISEDESIVLANuUESUNATOUTPOUReOMMU
NIjUERAxEeSESeOLLEuUESRUSSSESOUAMERIEAINSILAUradejUOISOeeUPERPUISjUESONPRO
uRAMMEDETRAxAILeOMPTAzILISEDENOMzREUSESEvPERIENeESAINSILEpEUNEASTRONAUTES
ERAeONNEeTEAUNETAzLETTEPOUReOLLEeTERDESDONNEESRELATIxEsALAPiYSIOLOuIEiUMA
INEeESETUDESSERxIRONtNOTAMMENTADEyINIRDEyAeONTRESPREeISEETALONuTERMELESzE
```

```
SOINSALIMENTAIRESDESASTRONAUTESLORSDESxOLSDELONuUEDUREE TELeELUjUIPOURRAP
OINDREMARSUNEAUTREMISSIONeONSISTERAATESTERLATiEORIEDELAuRAxITATIONSELONLA
jUELLELAuRAxITEAUNEINyLUENeESURLEeOULEMENTDUTEMPSPOURMESURERLETEMPSAxEeUN
EEvAeTITUDEETUNESTAzILITEINEuALEEUNEiORLOuEATOMIjUENOUxELLESERAINSTALLEEA
LEvTERIEURDELASTATIONORzITALEeETTEEvPERIENeEPERMETTRADESYNiRONISERAxEeUN
EPLUSuRANDEPREeISIONLESSYSTEMESDEPOSITIONNEMENTPARSATELLITE
```

C'est facile maintenant. $PLUSpEUNE \implies (p \rightarrow j)$, $DENOMzREUSESEvPERIENeES \implies (z \rightarrow B)$, $(v \rightarrow X)$ et $(e \rightarrow C)$, $ETUDESSERxIRONTE \implies (x \rightarrow v)$, $ADEyINIRDE \implies (y \rightarrow F)$.

Listing 33 – Suite de `Commandes.sce`

```
C9= 'AYcMCNOPIjRSTnIJqDLEuXUVFB' ;
M9=CoDec(M0, Alphabet , C9) ;
afficher ( 'M9=' ) ;
afficher (M9) ;
```

Listing 34 – M9

```
M9=
ILESTLEPLUSJEUNEEUROPEENAETRERETENUPOURUNEMISSIONSPATIALECESTUNTOUCiEATOU
TPUISjUILESTCEINTURENOIREDEJUDOETJOUEDUSAXOPiONEDES FACULTESDONTILNEDEVRAI
TPASAVOIRBESOINDUMOINSPASAUTANTjUESAMAITRISEDESIXLANuUESUNATOUTPOURCOMMUN
IjUERAVECSESCOLLEuUESRUSSESOUAMERICAINSILAURADEjUOISOCCUPERPUISjUESONPROu
RAMMEDETRAVAILCOMPTABILISEDENOMBREUSESEXPERIENCESAINSILEJEUNEASTRONAUTESE
RACONNECTEAUNETABLETTEPOURCOLLECTERDESDONNEESRELATIVESALAPiYSIOLOuIeIUMAI
NECESETUDESSERVIRONTNOTAMMENTADEFINIRDEFACONTRESPRECISEETALONuTERMELESBES
OINSALIMENTAIRESDESASTRONAUTESLORSDESVOLSDELONuUEDUREE TELCELUIjUIPOURRAJO
INDREMARSUNEAUTREMISSIONCONSISTERAATESTERLATiEORIEDELAuRAVITATIONSELONLAj
UELLELAuRAVITEAUNEINFLUENCESURLECOULEMENTDUTEMPSPOURMESURERLETEMPSAVECUNE
EXACTITUDEETUNESTABILITEINEuALEEUNEiORLOuEATOMIjUENOUVELLESERAINSTALLEEAL
EXTERIEURDELASTATIONORBITALECETTEEEXPERIENCEPERMETTRADESYNiRONISERAVECUNE
PLUSuRANDEPRECISIONLESSYSTEMESDEPOSITIONNEMENTPARSATELLITE
```

Enfin $TOUCiEATOUT \implies (i \rightarrow h)$, $PUISjUILEST \implies (j \rightarrow Q)$, $LANuUES \implies (u \rightarrow G)$.

Listing 35 – Suite de `Commandes.sce`

```
C10= 'AYcMCNOPHQIRSTnIJqDLEGXUVFB' ;
M10=CoDec(M0, Alphabet , C10) ;
afficher ( 'M10=' ) ;
afficher (M10) ;
```

ce qui termine le décodage du message M0³⁵ :

Listing 36 – Message décodé

```
M10=
ILESTLEPLUSJEUNEEUROPEENAETRERETENUPOURUNEMISSIONSPATIALECESTUNTOUCHEATOU
TPUISQUILESTCEINTURENOIREDEJUDOETJOUEDUSAXOPHONEDES FACULTESDONTILNEDEVRAI
TPASAVOIRBESOINDUMOINSPASAUTANTQUESAMAITRISEDESIXLANGUESUNATOUTPOURCOMMUN
IQUERAVECSESCOLLEGUESRUSSESOUAMERICAINSILAURADEQUOISOCCUPERPUISQUESONPROG
RAMMEDETRAVAILCOMPTABILISEDENOMBREUSESEXPERIENCESAINSILEJEUNEASTRONAUTESE
RACONNECTEAUNETABLETTEPOURCOLLECTERDESDONNEESRELATIVESALAPHYSIOLOGIEHUMAI
```

35. Extrait un peu modifié de [8]

NECESITUDESSEVRONTNOTAMMENTADEFINIRDEFACONTRESPRECISEETALONGTERMELESBE
SOINSALIMENTAIRESDESASTRONAUTESLORSDESVOLSDDELONGUEDUREEETELCELUQUIPOURRAJ
OINDREMARUNEAUTREMISSIONCONSISTERAATESTERLATHEORIEDELAGRAVITATIONSELONLA
QUELLELAGRAVITEAUNEINFLUENCESURLECOULEMENTDUTEMPSPOURMESURERLETEMPSAVECUN
EEXACTITUDEETUNESTABILITEINEGALEEUNEHORLOGEATOMIQUENOUVELLESERAINSTALLEEA
LEXTERIEURDELASTATIONORBITALECETTEEXPERIENCEPERMETTRADESYNCHRONISERAVECUN
EPLUSGRANDEPRECISIONLESSYSTEMESDEPOSITIONNEMENTPARSATELLITE

6.2 Commentaires

- On trouve d'autres exemples sur la toile. Ainsi, sur le site de *cryptage.org*, il y a un bel exemple entièrement traité et convaincant, voir [11].
- On trouve sur la toile des textes à décoder³⁶, voir par exemple [4].
- La méthode des fréquences a d'autres ressources comme l'utilisation des fréquences de bigrammes³⁷.
- Pour échapper à la menace de décodage sauvage par la méthode des fréquences, on peut la rendre inopérante en faisant intervenir dans le chiffrement plusieurs codages par substitution (cf. le chiffrement de Hill, [1] ou la machine ENIGMA, voir [7]).

7 Conclusion

7.1 Idées d'activités sur le thème du déchiffrement de messages codés

- On peut évidemment proposer des activités d'algorithmique où le déchiffrement est un simple prétexte³⁸. Par exemple, une substitution de lettres ayant été définie par une clef quelconque donnée, demander de programmer une fonction *scilab* jouant le rôle de la fonction *CoDec* ci-dessus, l'utiliser pour coder un texte donné, puis proposer le décodage d'un autre texte donné codé avec la même substitution de lettres³⁹.
- Si l'on veut vraiment mettre en œuvre la méthode des fréquences, on devra se limiter au lycée au cas qui marche, c'est à dire au déchiffrement d'un texte codé par décalage de pas inconnu, cf. 5.2.2.

7.2 Critique l'utilisation de la méthode des fréquences au lycée

La principale critique que l'on peut faire à la méthode des fréquences est qu'elle ne propose aucun modèle, c'est à dire aucun cadre mathématique dans lequel on pourrait justifier les calculs faits. Pire, quand on affirme que la méthode marche d'autant mieux que le message à décoder est plus long, on sent la présence importune de la loi des grands nombres⁴⁰. Si l'on pouvait prétendre que l'on écrit les messages codés en tirant leurs lettres successives au hasard dans l'alphabet suivant les fréquences communément admises, les tirages étant indépendants les uns des autres, cela définirait un modèle et on pourrait invoquer la fameuse loi. Mais, c'est bien évidemment absurde. Malgré tout, le risque de confusion est grand.

La méthode des fréquences ne se justifie pas mathématiquement. Ça marche⁴¹ quand on a du temps, de l'intuition et si possible de la chance.

36. qui ont été codés par substitution de lettres

37. Bigramme signifie couple de lettres. On peut s'intéresser à des bigrammes particuliers : bigrammes de voyelles, de consonnes, consonnes redoublées, *etc*, voir [3].

38. Par exemple, dans [1], il y avait une belle activité, difficile, sur le chiffrement de Hill, mais c'était surtout un problème de calcul matriciel et d'arithmétique.

39. ce qui nécessitera de comprendre que la fonction *scilab* écrite précédemment fonctionne aussi pour déchiffrer

40. qui n'est jamais invoquée explicitement

41. ce qui est agaçant !

Références

- [1] CHIFFREMENT DE HILL *Ressources pour la classe terminale et technologique, Mathématiques, Série S, Enseignement de spécialité*, BO spécial n° 8 du 13 octobre 2011, I, paragraphe LIV, *nrf*, Pléiade, Gallimard, 1968.
- [2] CHIFFREMENT PAR SUBSTITUTION.
<http://iml.univ-mrs.fr/%7Eerodier/Cours/Substitution.tpts.pdf>
- [3] FRÉQUENCES DES LETTRES, BIGRAMMES, TRIGRAMMES, QUADRIGRAMMES EN FRANÇAIS, Site de Bibm@th.net.
http://www.bibmath.net/crypto/index.php?action=affiche&quoi=chasseur/frequences_francais
- [4] FRÉQUENCES DES LETTRES EN FRANÇAIS, Site de Apprendre-en-ligne.net.
<http://www.apprendre-en-ligne.net/crypto/stat/francais.html>
- [5] FRÉQUENCES DES LETTRES ET POLYGRAMMES DANS LA LANGUE FRANÇAISE, Site de Bibm@th.net.
<http://bibmath.net/forums/viewtopic.php?id=3767>
- [6] HISTORIENS ROMAINS. HISTORIENS DE LA RÉPUBLIQUE II *César La guerre civile* I, paragraphe LIV, *nrf*, Pléiade, Gallimard, 1968.
- [7] LAPÔTRE PIERRE & RAYMOND MOCHÉ, La machine ENIGMA, activité
http://www.gradus-ad-mathematicam.fr/TS_Algorithmique4.htm
- [8] MONIER PIERRE *Thomas Pesquet, le numéro 10 de l'équipe spatiale française*, article publié le 21 novembre 2015 sur le site de *L'usine nouvelle*, section Spatial.
- [9] SITE DE SCILAB.
<http://www.scilab.org/fr/>
- [10] SITE DE CRYPTAGE.ORG
<http://www.cryptage.org>
- [11] TABLEAU DES FRÉQUENCES POUR LA LANGUE FRANÇAISE, Site de cryptage.org.
<http://www.cryptage.org/analyse-frequentielle.html>
- [12] WIKIPEDIA. *American Standard for Information Interchange*
https://fr.wikipedia.org/wiki/American_Standard_Code_for_Information_Interchange
- [13] WIKIPEDIA. *Chiffrement par décalage*
https://fr.wikipedia.org/wiki/Chiffrement_par_decalage
- [14] WIKIPEDIA. *Chiffrement par substitution*
https://fr.wikipedia.org/wiki/Chiffrement_par_substitution

