

# Statistical Methods for Cryptography

**Alfredo Rizzi**

**Dipartimento di Statistica, Probabilità e Statistiche  
Applicate**

**Università di Roma "La Sapienza"**

**P.le A.Moro, 5 - 00185 Roma**


**[alfredo.rizzi@uniroma1.it](mailto:alfredo.rizzi@uniroma1.it)**

- Cryptography
- Cryptoanalysis

- Encrypt
- Decrypt

- Linguistics, in particular Statistical Linguistics;
- Statistics, in particular the Theory of the Tests for the Analysis of Randomness and of Primality and Data Mining;
- Mathematics, in particular Discrete Mathematics;

- Bob Encrypt
- Alice Decipher
- Eve Decrypt



- Caesar Code:  
Monoalphabetic Substitution

SENATUSPOPULUSQUEROMANUS  
VHQDWXVSRSXOXVTXHURPDQXV

Key=3

- Maths:

$$24! = 6.2045e+23$$

finite solution number

- Information Theory:

$$6.2045e+14$$

$$3.1710e+06 \text{ Years}$$

- Vigenère:


Multialphabetic Cipher

*Traicté des chiffres où secrètes  
manières d'escire 1586*

## PLAINTEXT

| KEY | A B C D E F G H I L M N O P Q R S T U V Z |
|-----|-------------------------------------------|
| A   | A B C D E F G H I L M N O P Q R S T U V Z |
| B   | B C D E F G H I L M N O P Q R S T U V Z A |
| C   | C D E F G H I L M N O P Q R S T U V Z A B |
| D   | D E F G H I L M N O P Q R S T U V Z A B C |
| E   | E F G H I L M N O P Q R S T U V Z A B C D |
| F   | F G H I L M N O P Q R S T U V Z A B C D E |
| G   | G H I L M N O P Q R S T U V Z A B C D E F |
| H   | H I L M N O P Q R S T U V Z A B C D E F G |
| I   | I L M N O P Q R S T U V Z A B C D E F G H |
| L   | L M N O P Q R S T U V Z A B C D E F G H I |
| M   | M N O P Q R S T U V Z A B C D E F G H I L |
| N   | N O P Q R S T U V Z A B C D E F G H I L M |
| O   | O P Q R S T U V Z A B C D E F G H I L M N |
| P   | P Q R S T U V Z A B C D E F G H I L M N O |
| Q   | Q R S T U V Z A B C D E F G H I L M N O P |
| R   | R S T U V Z A B C D E F G H I L M N O P Q |
| S   | S T U V Z A B C D E F G H I L M N O P Q R |
| T   | T U V Z A B C D E F G H I L M N O P Q R S |
| U   | U V Z A B C D E F G H I L M N O P Q R S T |
| V   | V Z A B C D E F G H I L M N O P Q R S T U |
| Z   | Z A B C D E F G H I L M N O P Q R S T U V |

- Lo statistico:  
Distribuzione di frequenze  
Parola Probabile



- Index of coincidence for letter frequency (W.F. Friedman 1926)

$$I_c = \sum \frac{n_i(n_i - 1)}{N \cdot (N - 1)}$$

Per la distribuzione campionaria di  $I_c$

$$N \cdot (N - 1) \cdot I_c + N = \sum n_i^2$$

Con semplici passaggi algebrici, sottraendo ad ambo i membri della precedente  $n^2/r$  e dividendo per  $r$ , si ha:

$$1/r \cdot [N \cdot (N - 1) I_c + N - N^2/r] = \sum n_i^2/r - N^2/r$$

Tenuto conto che  $\sum n_i^2/r$  è il secondo momento e  $N^2/r^2$  è il quadrato della media aritmetica, il secondo membro della precedente relazione è uguale alla varianza campionaria che verrà indicata con  $s^2$ . Se si suppone costante ed uguale ad  $1/r$  la probabilità che ad una prova qualsiasi si verifichi uno qualsiasi dei simboli dell'alfabeto, per la varianza della distribuzione si avrà :

$$\sigma^2 = N \cdot 1/r \cdot (1 - 1/r)$$

Ricordando che:  $\chi^2 = f \cdot s^2 / \sigma^2$  ove  $f$  sono i gradi di libertà che nel nostro caso sono  $r-1$ .


Sostituendo nella espressione precedente le due espressioni di  $\sigma^2$  e di  $s^2$ , dopo alcune semplificazioni algebriche si ha:

$$\chi^2 = r \cdot (N - 1) \cdot (I_c - 1) \text{ con } r-1 \text{ gdl.}$$

Esplicitando  $I_c$ :

$$I_c = (\chi^2)/r \cdot (N - 1) + 1.$$

## ■ ENIGMA



- 1) SCAMBIATORE
- 2) ROTORI
- 3) PANNELLO RETROILLUMINATO OUTPUT
- 4) BATTERIA
- 5) TASTIERA
- 6) PLUGBOARD O STEKER

## ■ MACCHINA DI TURING

## ■ Theorem 1

Let two discrete s.v. (statistical variable)  $X, Y$  assume the value:  $0, 1, 2, \dots, m-1$ .  
Let  $X$  be uniformly distributed, that is it assumes the value  $i$  ( $i = 0, 1, \dots, m-1$ ) with probability  $1/m$  and let the second s.v.  $Y$  assume the value  $i$  with probability  $p_i$ .  
Then, if the two s.v. are independent, it follows that the s.v.  $Z$  obtained as a sum modulo  $m$  is uniformly distributed.

- *Proof.* If the s.v.  $X$  assumes the value  $i$ , then the s.v.  $Z$  can assume the values:  
 $i, i+1, i+2, \dots, m-1, 0, 1, 2, \dots, i-1$   
respectively with probabilities:  
 $p_0, p_1, \dots, p_{m-1-i}, \dots, p_{m-1}$

according to the values

$0, 1, 2, \dots, m-i, m+1-i, m+2-i, \dots, m-1$   
assumed by the  $Y$ .

- If we let  $i$  assume the values  $0, 1, 2, \dots, m-1$ , it follows that the s.v.  $Z$  assumes the general value  $h$  ( $h = 0, 1, \dots, m-1$ ) with probability:

$$\left\{ \begin{array}{lll} \frac{1}{m} p_h & \text{if } X = 0 & Y = h \\ \frac{1}{m} p_{h-1} & \text{if } X = 1 & Y = h-1 \\ \vdots & \vdots & \vdots \\ \frac{1}{m} p_0 & \text{if } X = h & Y = 0 \\ \vdots & \vdots & \vdots \\ \frac{1}{m} p_{h-1} & \text{if } X = m-1 & Y = h+1 \end{array} \right.$$

It follow immediately by summation:

$$P(Z = h) = \frac{1}{m} \sum_{i=0}^h p_i + \frac{1}{m} \sum_{i=h+1}^{m-1} p_i = \frac{1}{m}$$

The above Theorem can be easily generalized to the sum (mod  $m$ ) of  $n$  s.v., one of which be uniformly distributed.

## ■ Theorem 2

Let two independent s.v.  $X$  and  $Y$  assume the values:  $0, 1, 2, \dots, m-1$  respectively with probabilities:

$$p_0, p_1, \dots, p_{m-1-i}, \dots, p_{m-1}$$

$$q_0, q_1, \dots, q_{m-1-i}, \dots, q_{m-1}$$

Then, if the s.v.  $Z = X + Y \pmod{m}$  is uniformly distributed and  $m$  is a prime number, at least one the two s. v.  $X$  and  $Y$  is uniformly distributed.

- Proof : The table of the sum (mod  $m$ ) of the s.v.  $X$  and  $Y$  is as follows:

|          | 0     | 1     | 2 | ... | $i$   | ... | $m-2$            | $m-1$            |           |
|----------|-------|-------|---|-----|-------|-----|------------------|------------------|-----------|
| 0        | 0     | 1     | 2 |     | $i$   |     | $m-1$            | $m-1$            | $p_0$     |
| 1        | 1     | 2     | 3 |     | $i+1$ |     | $m-1$            | 0                | $p_1$     |
| 2        | 2     | 3     | 4 |     | $i+2$ |     | 0                | 1                | $p_2$     |
| $\vdots$ |       |       |   |     |       |     |                  |                  |           |
| $j$      | $j$   | $j+1$ |   |     | $i+j$ |     | $j+m-2 \pmod{m}$ | $j+m-1 \pmod{m}$ | $p_j$     |
| $\vdots$ |       |       |   |     |       |     |                  |                  |           |
| $m-1$    | $m-1$ | 0     |   |     | $i-1$ |     | $m-3$            | $m-2$            | $p_{m-1}$ |
|          | $q_0$ | $q_1$ |   |     | $q_i$ |     | $q_{m-2}$        | $q_{m-1}$        | 1         |

- As the  $X$  and  $Y$  are independent, the s. v.  $Z$  assumes the value 0 with probability:

$$p_0q_0 + \cdots + p_2q_{m-2} + p_1q_{m-1}$$

Such probability, according to the hypothesis of uniform distribution of  $Z$ , must be  $1/m$ .

By the same token, in order to compute the probabilities that the s.v.  $Z$  assumes the values  $1, 2, \dots, m-1$ , the following system can be written:

$$\begin{cases} p_0q_0 + p_{m-1}q_1 + \cdots + p_2q_{m-2} + p_1q_{m-1} = 1/m \\ p_1q_0 + p_0q_1 + \cdots + p_3q_{m-2} + p_2q_{m-1} = 1/m \\ p_2q_0 + p_1q_1 + \cdots + p_4q_{m-2} + p_3q_{m-1} = 1/m \\ \vdots \\ p_{m-1}q_0 + p_{m-2}q_1 + \cdots + p_1q_{m-2} + p_0q_{m-1} = 1/m \end{cases}$$

- If  $p_i$  are known (the reasoning is the same if the  $q_i$  are known) the above system is a system of  $m$  equations in the  $m$  unknowns .
- It follows:

$$q_i = \frac{\begin{vmatrix} p_0 p_{m-1} & \cdots & 1/m & \cdots & p_1 \\ p_1 p_0 & \cdots & 1/m & \cdots & p_2 \\ \vdots & & & & \\ p_{m-1} p_{m-2} & \cdots & 1/m & \cdots & p_0 \end{vmatrix}}{\Delta}$$

- Where  $\Delta$  is the determinant of the matrix of the coefficients, and it can be easily seen to be 0 if at least one. ( In the opposite case the s. v.  $X$  is uniformly distributed ). In fact, it is a circulating determinant.

- In order to show the theorem in general, it is sufficient to show that

$$q_i = q_0 \quad \forall i = 1, 2, \dots, m-1$$

- In this case, as  $\sum q_i = 1$ ,  $q_i \geq 0$ ,  $q_i = 1/m$ .
- Then, it is sufficient to show that:

$$\begin{vmatrix} 1/m & p_{m-1} & \cdots & p_1 \\ 1/m & p_0 & \cdots & p_2 \\ \vdots & p_{m-1} & & \\ 1/m & p_{m-2} & \cdots & p_0 \end{vmatrix} = \begin{vmatrix} p_0 & p_{m-1} & \cdots & 1/m & \cdots & p_1 \\ p_1 & p_0 & \cdots & 1/m & \cdots & p_2 \\ \vdots & & & & & \\ p_{m-1} & p_{m-2} & \cdots & 1/m & \cdots & p_0 \end{vmatrix}$$

- The two determinants are equal because, in order to transform the second into the first one, it is necessary to perform, owing to the circulating nature of the permutations of the  $p_i$ ,  $m-2$  inversions over the rows and  $m-2$  inversions over the columns, that is  $2(m-1)$  inversions over rows and columns in all. If an even number of inversions is performed, the sign of the determinant is unchanged.

- In this way, for instance, if  $m-1=3$  we have that the numerator of  $q_0$  is

$$\begin{vmatrix} 1/3 & p_1 & p_2 \\ 1/3 & p_2 & p_0 \\ 1/3 & p_0 & p_1 \end{vmatrix} = \begin{vmatrix} p_0 & 1/3 & p_2 \\ p_1 & 1/3 & p_0 \\ p_2 & 1/3 & p_1 \end{vmatrix}$$

## SCHIFT REGISTERS:

consentono di ottenere sequenze pseudo-casuali, che *sembrano* essere casuali, anche se analisi approfondite consentono di individuare alcune regolarità.

- La pseudo-casualità va intesa nel senso che:
- Il numero degli 1 deve essere approssimativamente uguale a quello degli zeri. Analogamente la frequenza di ognuna delle quattro coppie, (00) (01) (10) (11), deve essere approssimativamente la stessa; ciò deve valere anche per le 9 terne di 3 elementi, e così via, per le  $2^n$  ennuple di  $n$  elementi.
- Sequenze di pochi 1 o di zeri devono essere più frequenti delle sequenze lunghe di 1 o di zeri.
- L'intera sequenza non deve avere autocorrelazione e la frequenza di ogni  $k$ -upla ( $k=1, 2, \dots, n$ ), deve essere la stessa; ad esempio per  $k=3$  la terna 000 deve avere la stessa frequenza di 001, 010, ... 111.

- Il funzionamento degli shift registers. Sia  $x_0$  un vettore di  $n+1$  componenti:
  - $x_0 \equiv \parallel x_{0,0}; x_{1,0}; x_{2,0}; \dots; x_{n,0} \parallel$con  $x_{i,0}$  ( $i=0,1,\dots,n$ ) cifre binarie non tutte nulle. Consideriamo, inoltre, l'evoluzione del vettore nel tempo :

- $x_t \equiv \parallel x_{0,t}; x_{1,t}; x_{2,t}; \dots; x_{n,t} \parallel$

con:

$$x_{n,t} = x_{n-1,t-1}$$

$$x_{n-1,t} = x_{n-2,t-1}$$

$$x_{n-2,t} = x_{n-3,t-1}$$

.....

$$x_{1,t} = x_{0,t-1}$$

$$x_{0,t} = f(x_{1,t}; x_{2,t}; \dots; x_{n,t})$$

- In definitiva un registro a scorrimento lineare è così caratterizzato:
- E' costituito da  $n+1$  celle ognuna contenente una cifra binaria;
- Evolve dallo stato  $t-1$  allo stato  $t$ ,  $t=1, \dots, r, \dots$  riempiendo tutte le  $n$  celle da 1 ad  $n$  con il contenuto della cella immediatamente a sinistra nello stato  $t-1$ .
- Allo stato iniziale il contenuto di almeno una cella è 1.
- Il contenuto della cella 0 al tempo  $t$  è calcolato come funzione lineare delle celle da 1 a  $n$  dello stesso stato  $t$ .
- La lunghezza massima del periodo è  $2^n - 1$
- Il periodo della sequenza è massimo qualora i coefficienti  $c_i$ , ( $i=1, 2, \dots, n$ ), siano quelli di un polinomio primitivo

- TEOREMA 1.

La lunghezza massima del periodo di un registro a scorrimento lineare di dimensione  $n$  è  $2^n - 1$ .

- TEOREMA 2

- Se il registro a scorrimento ha periodo massimo, allora i coefficienti  $c_i$  ( $i=1,2,\dots,n$ ) sono coefficienti di un polinomio irriducibile di grado  $n$  in  $GF(2)$ .

- Si noti che l'inverso del teorema non è valido come si verifica nell'esempio 3.

- Ricordiamo che: In  $GF(p)$  un polinomio intero di grado  $n$  è primitivo se, oltre ad essere irriducibile, ossia non essere il prodotto di almeno due polinomi di grado  $\geq 1$ , divide  $x^{p^n-1}$  per  $n$  non inferiore a  $p^n-1$ .

# Fermat's little theorem (1637)

- Let  $a, p$  integer |  $(a, p)=1$ . If  $p$  is prime  
then:

$$a^{p-1} \equiv 1 \pmod{p}$$

- The composite  $p$  for which Fermat's little theorem is true for every  $a$  are called Carmichael numbers.  
the first three are 561, 1105, 1729.  
Although these number are very rare, it is proved that there are infinitely many of them.

- P we can find the solution in polynomial time  $O(f(n))$
- NP (Non-deterministic Polynomial) we can just check the solution in polynomial time

# M.Agrawal, N.Kayal and N. Saxena

- deterministic test based on the following:
- Theorem 4:  
p is prime if and only if  
 $(x-a)^p \equiv (x^p-a) \pmod{p}$   
where a is a number prime with p.

- Agrawal, Kayal and Saxena

algorithm would run in at most  $O((\log n)^{12}f(\log \log n))$  time where  $f$  is a polynomial.