Jak (nie) szyfrować wiadomości?

Łamanie szyfrów dla początkujących

Jacek Rogowski

Instytut Matematyki

Politechniki Łódzkiej

Kryptologia

Kryptologia jest nauką o całokształcie metod utajniania i ochrony informacji oraz o sposobach odczytywania informacji z utajnionych tekstów

Podział kryptologii

- **Kryptografia –** nauka o bezpiecznych metodach szyfrowania
- **Kryptoanaliza** – nauka o odczytywaniu informacji z zaszyfrowanych tekstów bez znajomości klucza

Rodzaje szyfrów

- **Szyfry podstawieniowe** – za każdy znak tekstu jawnego podstawia się umowny znak, zgodnie z ustalonym *kluczem*
- **Szyfr przestawieniowy** – znaki tekstu jawnego przestawia się według umownej zasady, zgodnie z ustalonym *kluczem*

Założenia kryptologii

- Algorytm szyfrowania jest znany wrogowi
- Znany jest język w jakim została napisana wiadomość
- Przeciwnik jest, co najmniej, tak samo inteligentny, jak my
- Należy zawsze przewidywać najgorszy scenariusz wydarzeń

Najprostszy szyfr podstawieniowy

- Każdej literze alfabetu tekstu jawnego przyporządkowany jest pewien ustalony symbol (liczba, litera, rysunek…).
- Przyporządkowanie to jest jednoznaczne i niezmienne. Nazywamy je **kluczem**.
- Ten sam klucz służy do szyfrowania i deszyfrowania wiadomości.

Szyfr Cezara

Każda litera jest zastępowana literą stojącą o 3 miejsca (lub inną ich liczbę) dalej w alfabecie, przy czym trzy ostatnie litery alfabetu (x, y, z) zastępowane są odpowiednio przez trzy początkowe jego litery (A, B, C).

Przykład:

s z y f r

V C B I U

Łamanie prostego szyfru podstawieniowego

- Element kryptoanalizy polegający na odczytaniu zaszyfrowanej wiadomości bez znajomości klucza szyfru.
- Testowanie wszystkich możliwych kluczy jest nieefektywne.
- Dla alfabetu złożonego z 26 liter i prostego szyfru podstawieniowego istnieje ponad

  400 kwadrylionów

  możliwych kluczy.

Analiza częstotliwości

Metoda porównująca częstotliwość występowania znaków tekstu tajnego z częstotliwością występowania liter w tekstach danego języka – w kolejnych próbach pod najczęściej występujące znaki kryptogramu podstawia się najczęściej występujące litery.

Tabela częstotliwości dla alfabetu polskiego (w %)

a/ą	9,90	g	1,42	m	2,80	t	3,98
b	1,47	h	1,08	n/ń	5,72	u	2,50
c/ć	4,36	i	8,21	o/ó	8,60	w	4,65
d	3,25	j	2,28	p	3,13	x	0,02
e/ę	8,77	k	3,51	r	4,69	y	3,76
f	0,30	l/ł	3,92	s/ś	4,98	z/ż/ź	6,53

Najczęściej występujące samogłoski (w %)

a/ą	9,90	g	1,42	m	2,8	t	3,98
b	1,47	h	1,08	n/ń	5,72	u	2,50
c/ć	4,36	i	8,21	o/ó	8,60	w	4,65
d	3,25	j	2,28	p	3,13	x	0,02
e/ę	8,77	k	3,51	r	4,69	y	3,76
f	0,30	l/ł	3,92	s/ś	4,98	z/ż/ź	6,53

Najczęściej występujące spółgłoski (w %)

a/ą	9,90	g	1,42	m	2,8	t	3,98
b	1,47	h	1,08	n/ń	5,72	u	2,50
c/ć	4,36	i	8,21	o/ó	8,60	w	4,65
d	3,25	j	2,28	p	3,13	x	0,02
e/ę	8,77	k	3,51	r	4,69	y	3,76
f	0,30	l/ł	3,92	s/ś	4,98	z/ż/ź	6,53

Przykład

Tekst w języku polskim zaszyfrowano prostym szyfrem podstawieniowym i otrzymano następujący szyfrogram:

XFJDTE SODOBT PYJMKO ZTXUOZ DCIJES NAOISO TDYPOZ JDLTED HWEJMK OJOKST SNXSOL SCONXM ESCUOI SOJIIU NA

Należy odczytać wiadomość jawną.

Etap I: Zliczanie

A	2	G	0	M	3	T	6
B	1	H	1	N	4	U	3
C	3	I	5	O	13	W	1
D	6	J	7	P	2	Y	2
E	5	K	3	R	0	Z	3
F	1	L	2	S	9	X	4

Etap I: Częstotliwości (w %)

A	2,3	G	0	M	3,5	T	7,0
B	1,2	H	1,2	N	4,7	U	3,5
C	3,5	I	5,8	O	15,1	W	1,2
D	7,0	J	8,1	P	2,3	Y	2,3
E	5,8	K	3,5	R	0	Z	3,5
F	1,2	L	2,3	S	10,5	X	4,7

Etap II: Wstępna analiza

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

Etap II: Wstępna analiza

- Tekst nie jest długi.
- Użycie symbolu X sugeruje, że któraś litera oznacza spację.
- *Hipoteza:* Spacja jest szyfrowana najczęściej występującym symbolem **O** (15,1% wszystkich liter).
- Usuwamy symbol **O.**

Etap III: Pierwsza litera

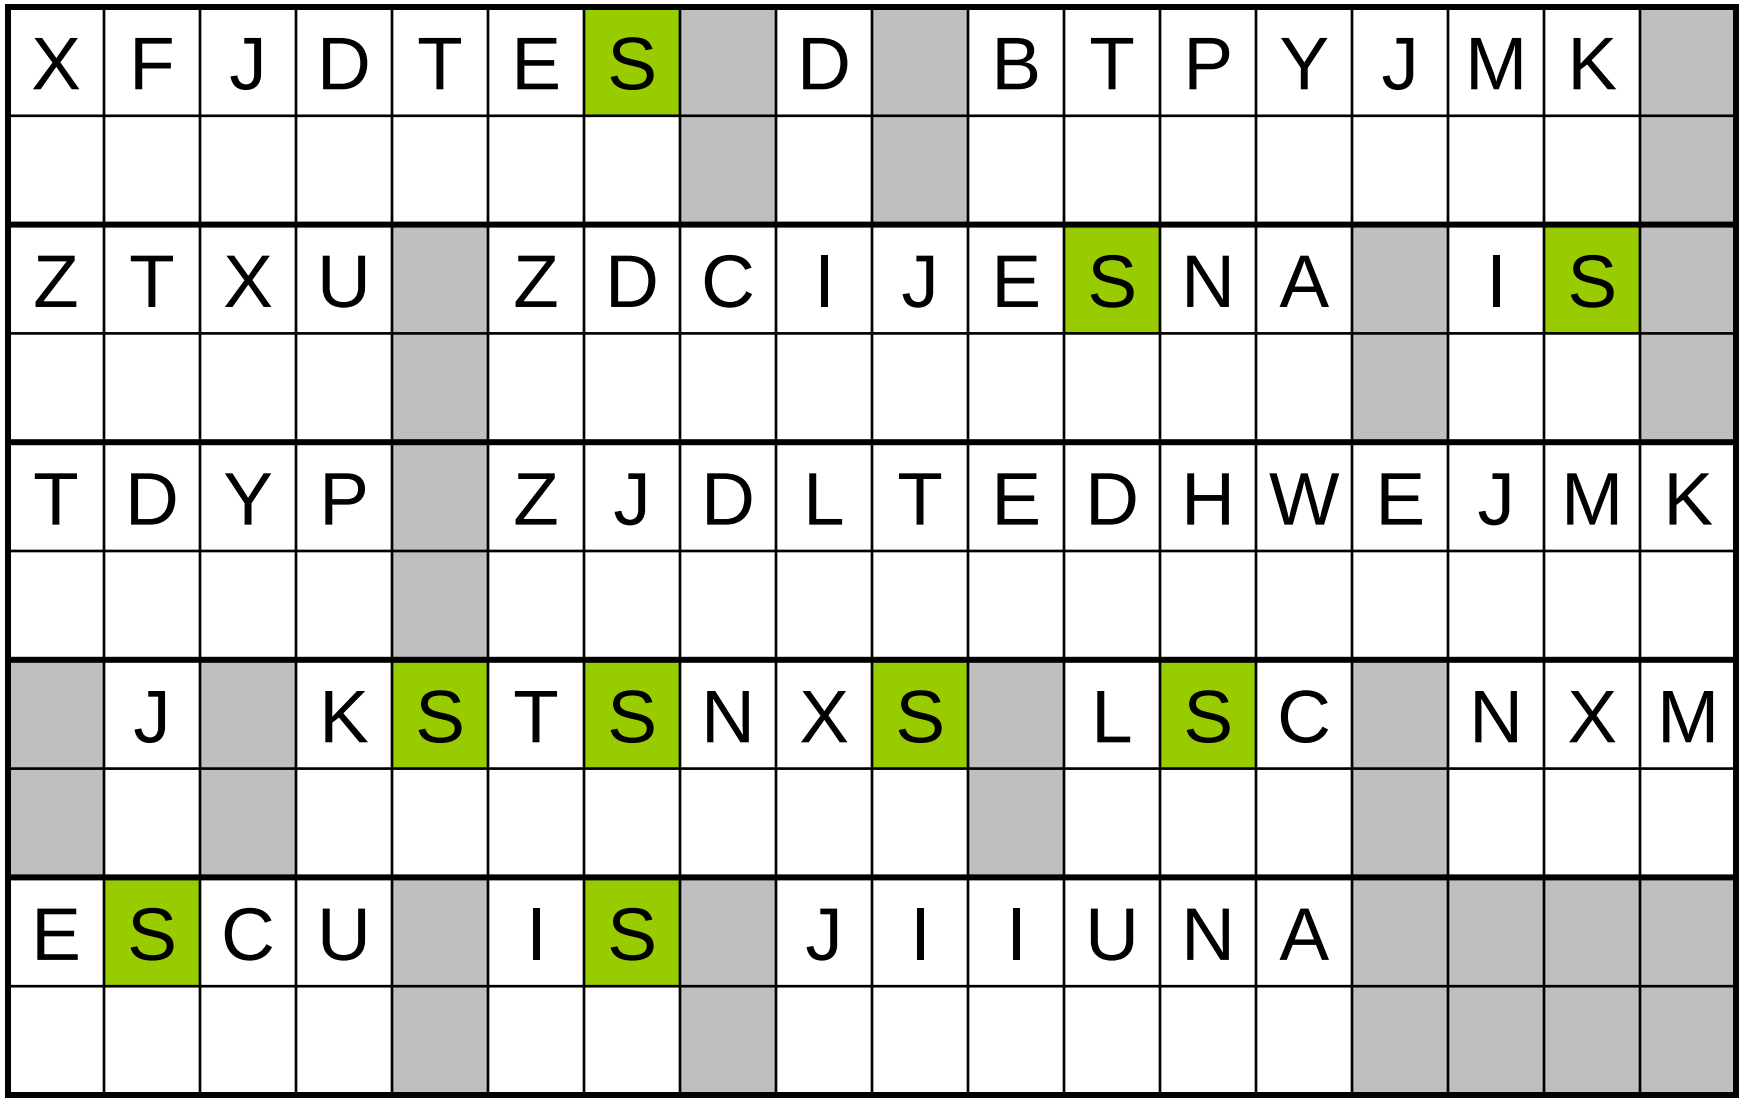

Etap III: Pierwsza litera

- *Hipoteza:* Następny, co do ilości wystąpień, symbol **S** (10,5% wszystkich liter) oznacza prawdopodobnie literę **a.**
- Podstawiamy **a** w miejsce **S**.

Etap III: Pierwsza litera

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
						a											
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
											a					a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
				a		a			a			a					
E	S	C	U		I	S		J	I	I	U	N	A				
	a					a											

Etap IV: Kolejne litery

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
						a											
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
											a					a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
				a		a			a			a					
E	S	C	U		I	S		J	I	I	U	N	A				
	a					a											

Etap IV: Kolejne litery

- Symbol **l** występuje 5 razy (5,8% wszystkich liter), a w ostatnim wyrazie pojawia się zdublowany.
- *Hipoteza:* **l** = **n.**
- Hipoteza ta jest potwierdzana przez dwukrotne pojawienie się słowa **na.**

Etap IV: Kolejne litery

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
						a											
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
								n			a				n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
				a		a			a			a					
E	S	C	U		I	S		J	I	I	U	N	A				
	a				n	a			n	n							

Etap IV: Kolejne litery

- Symbole **D** i **J** występują jako spójniki.
- Częstotliwości ich występowania (7,0% i 8,1%) odpowiadają częstotliwościom samogłosek **o**, **i** lub spółgłoski **z.**
- Symbol **J** rozpoczyna ostatni wyraz, a po nim znajdują się dwie litery **n.**
- *Hipoteza:* **J** = **i.**

Etap IV: Kolejne litery

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
		i				a								i			
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
								n	i		a				n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
						i									i		
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i			a		a			a			a					
E	S	C	U		I	S		J	I	I	U	N	A				
	a				n	a		i	n	n							

Etap IV: Kolejne litery

- Symbol **D** może oznaczać **o** lub **z.**
- Częstotliwość występowania litery **o** (8,60%) jest większa od częstotliwości występowania litery **z** (6,53%), a więc częstsze pojawienie się litery **o** jest bardziej prawdopodobne.
- *Hipoteza:* **D** = **o.**

Etap IV: Kolejne litery

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
		i	o			a		o						i			
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
						o		n	i		a				n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	o					i	o				o				i		
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i			a		a			a			a					
E	S	C	U		I	S		J	I	I	U	N	A				
	a				n	a		i	n	n							

Etap IV: Kolejne litery

- Ostatnim słowem może być **innemu**, **innych** lub **innego**, ale **o** zostało już rozszyfrowane.
- Częstotliwości występowania liter w trigramie UNA (3,5 – 4,7 – 2,3) lepiej pasują do częstotliwości liter w trigramie **ych** (3,76 – 4,36 – 1,08) niż w trigramie **emu** (8,77 – 2,80 – 2,50).
- *Hipoteza:* **U** = **y**, **N** = **c**, **A** = **h.**

Etap IV: Kolejne litery

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
		i	o			a		o						i			
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
			y			o		n	i		a	c	h		n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	o					i	o				o				i		
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i			a		a	c		a			a			c		
E	S	C	U		I	S		J	I	I	U	N	A				
	a		y		n	a		i	n	n	y	c	h				

Etap IV: Kolejne litery

- Symbol **X** występuje cztery razy, w tym dwukrotnie w zestawieniu **cX**, a raz w zestawieniu **Xy**
- *Hipoteza:* **X** = **z.**

Etap IV: Kolejne litery

X	F	J	D	T	E	S	■	D	■	B	T	P	Y	J	M	K	■
z		i	o			a	■	o	■					i			■
Z	T	X	U	■	Z	D	C	I	J	E	S	N	A	■	I	S	■
		z	y	■		o		n	i		a	c	h	■	n	a	■
T	D	Y	P	■	Z	J	D	L	T	E	D	H	W	E	J	M	K
	o			■		i	o				o				i		
■	J	■	K	S	T	S	N	X	S	■	L	S	C	■	N	X	M
■	i	■		a		a	c	z	a	■		a		■	c	z	
E	S	C	U	■	I	S	■	J	I	I	U	N	A	■	■	■	■
	a		y	■	n	a	■	i	n	n	y	c	h	■	■	■	■

Etap V: Uzupełnianie luk

- Zestawmy wyniki przeprowadzonej analizy.
- Dla ułatwienia zaznaczmy odgadnięte litery na niebiesko.
- Następnie, wśród pozostałych znaków kryptogramu wskażmy te o największych częstotliwościach.

Etap V: Uzupełnianie luk

A=h	2,3	G	0	M	3,5	T	7,0
B	1,2	H	1,2	N=c	4,7	U=y	3,5
C	3,5	I=n	5,8	O=_	15,1	W	1,2
D=o	7,0	J=i	8,1	P	2,3	Y	2,3
E	5,8	K	3,5	R	0	Z	3,5
F	1,2	L	2,3	S=a	10,5	X=z	4,7

Etap V: Uzupełnianie luk

- Analogiczne działania przeprowadźmy dla liter alfabetu polskiego

Etap V: Uzupełnianie luk

a/ą=S	9,90	g	1,42	m	2,80	t	3,98
b	1,47	h=A	1,08	n/ń=I	5,72	u	2,50
c/ć=N	4,36	i=J	8,21	o/ó=D	8,60	w	4,65
d	3,25	j	2,28	p	3,13	x	0,02
e/ę	8,77	k	3,51	r	4,69	y=U	3,76
f	0,30	l/ł	3,92	s/ś	4,98	z/ż/ź=X	6,53

Etap V: Uzupełnianie luk

- Przynajmniej niektóre znaki ze zbioru

  C, E, K, M, T, Z

  odpowiadają pewnym literom spośród

  e/ę, r, s/ś, t, w
- W szczególności jeden z powyższych znaków powinien reprezentować literę e/ę

Etap V: Uzupełnianie luk

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
z		i	o			a		o						i	e		
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
		z	y			o		n	i		a	c	h		n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	o					i	o				o				i	e	
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i			a		a	c	z	a			a			c	z	e
E	S	C	U		I	S		J	I	I	U	N	A				
	a		y		n	a		i	n	n	y	c	h				

Etap V: Uzupełnianie luk

- Przyjmijmy więc, że **M = e.**
- Słowo **czeEaCy** sugeruje, że

  C = **m**, **E** = **k.**

Etap V: Uzupełnianie luk

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
z		i	o		k	a		o						i	e		
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
		z	y			o	m	n	i	k	a	c	h		n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
	o					i	o			k	o			k	i	e	
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i			a		a	c	z	a			a	m		c	z	e
E	S	C	U		I	S		J	I	I	U	N	A				
k	a	m	y		n	a		i	n	n	y	c	h				

Etap V: Uzupełnianie luk

- Stosując metodę prób i błędów dla najbardziej prawdopodobnych liter dostajemy **Z** = **p**, **T** = **r.**

Etap V: Uzupełnianie luk

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
z		i	o	r	k	a		o			r			i	e		
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
p	r	z	y		p	o	m	n	i	k	a	c	h		n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
r	o				p	i	o		r	k	o			k	i	e	
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i			a	r	a	c	z	a			a	m		c	z	e
E	S	C	U		I	S		J	I	I	U	N	A				
k	a	m	y		n	a		i	n	n	y	c	h				

Etap V: Uzupełnianie luk

- Teraz można już bez trudu uzupełnić resztę tekstu.

Etap V: Uzupełnianie luk

X	F	J	D	T	E	S		D		B	T	P	Y	J	M	K	
z	b	i	o	r	k	a		o		d	r	u	g	i	e	j	
Z	T	X	U		Z	D	C	I	J	E	S	N	A		I	S	
p	r	z	y		p	o	m	n	i	k	a	c	h		n	a	
T	D	Y	P		Z	J	D	L	T	E	D	H	W	E	J	M	K
r	o	g	u		p	i	o	t	r	k	o	w	s	k	i	e	j
	J		K	S	T	S	N	X	S		L	S	C		N	X	M
	i		j	a	r	a	c	z	a		t	a	m		c	z	e
E	S	C	U		I	S		J	I	I	U	N	A				
k	a	m	y		n	a		i	n	n	y	c	h				