

## Frekvenční analýza a substituční šifra pro začátečníky

Před nějakou dobou jsem luštil jednu obzvláště vypečenou mystery keš z okolí Plzně. Když jsem vyčerpал všechny dobré nápady, došlo na frekvenční analýzu (FA). Prohledal jsem internet a našel několik slušných stránek o tom, jak frekvenční analýza funguje a dokonce stáhnul i pár šifrovacích programů, které FA umějí. Žádný z programů, ale nedokázal uživatelsky přívětivě proměnit výsledek analýzy v rozšifrovaný text. To mě přimělo vytvořit vlastní jednoduchý program, díky kterému se mi podařilo šifru rozluštit. V tomto krátkém článku bych se rád podělil o program samotný a o zkušenosti s jeho použitím.

- 1) **Co je frekvenční analýza?** Stručně řečeno, je to analýza frekvence, tedy četnosti výskytu jednotlivých znaků v textu. Pokud máme například text o 100 písmenech a písmenko „A“ se v něm vyskytuje 10x, „B“ 5x a „C“ 1x, znamená to, že průměrná četnost písmena „A“ v daném textu je 10%, „B“ 5% a „C“ 1%... Tímto způsobem zjistíme četnost výskytu všech v textu obsažených znaků. Důležité je zmínit, že v každém jazyce jsou výskyty písmen různé. Tedy četnost výskytu písmene „a“ v češtině se bude lišit od četnosti výskytu písmene „a“ v angličtině. Na internetu se dají najít frekvence znaků pro většinu řečí, češtinu nevyjímaje. Další důležité upozornění je, že záleží na velikosti referenčního vzorku (čím více textu, tím přesnější čísla) a na druhu textu, který analyzujete. Například kapitola o chovu okounů bude mít jinou četnost výskytu písmene „O“, než například text písničky Královské Rege, kde zase bude výrazně vyšší četnost písmene „R“.

**K čemu to mohu využít?** Frekvenční analýzu je možné použít na luštění různých polyalfabetických substitučních šifer – jednoduše – když jsou v textu nahrazena písmena jinými písmeny. Například: nezašifrovaný text: „Harry Potter“, zašifrovaný text: „jsttx úpzrt“.  
Případně, když jsou písmena nahrazena znaky, nebo obrázky.

- 2) **Jak to využít v praxi?** Uvádím příklad.

K rozluštění mám následující text:

„ΑΒΧΕΔΦΓ ΗΙΘΑΘ ΚΑΛ ΓΥΙΒΜΗΑ ΝΑ ΟΚΦΚΕΓΗΑΗΦ Α ΟΕΛΕΠΠΗΥΝΓΦ ΧΝΙΚ  
ΨΘΦ ΛΕΧΝΕΚ ΓΔΑΒΜ ΟΚΕΟΔΙΝΑ ΥΓΙ ΝΙΘΟΙΚΑΘΙΗΝΗΦ ΚΙΒΦ ΖΖΗΑΓΑΘ ΖΙ Η  
Α ΝΕΘ ΗΑΖΕΚΗΙΘ ΟΚΦΧΔΑΛΖ Υ ΧΑΓΑΚΗΕΖ ΒΛΕΓΙΧΙΘ Α ΘΦΥΕΖ ΧΕΠΔΦΜ ΗΙ  
ΒΕ ΣΙ ΔΖΙ ΗΑ ΗΙΘ ΑΥΟΕΗ ΟΚΦΠΔΦΖΗ ΖΧΑΖΑΝ ΣΑΧΨΘ ΒΛΕΓΙΧΙΘ ΣΙ ΥΑΝΖ  
ΚΗΦΗ ΛΕΧΝΕΚ ΓΔΑΒΜ ΥΦ ΝΕΝΦΖ ΚΕΖΛΙΔΦΔ ΔΦΛΦ ΟΕΛΔΙ ΝΕΜΕ ΣΑΧ ΥΙ  
ΒΜΕΓΑΣΦ Γ ΟΕΔΕΟΚΑΖΛΗ ΧΑΓΑΚΗΙ ΘΑΣΦΔΦ ΟΚΙΑ ΥΠΠΕΖ ΘΦΥΖ ΧΕΠΔΦΜ  
ΟΚΙΛΥΝΑΓΝΙ ΥΦ ΔΖΞΖΥΗΦ ΧΑΓΑΚΗΖ ΖΑ ΗΙΛΙΔΗΦΜΕ ΕΛΟΕΔΙΛΗΙ ΓΙΗΧΖ ΣΙ Χ  
ΚΑΥΗΨ ΛΙΗ Α ΜΕΥΝΖ Γ ΧΑΓΑΚΗΙ ΣΙ ΘΑΔΕ ΖΖ ΣΥΝΙ ΥΙ ΗΑΥΗΦΛΑΔΦ ΟΚΙΒΙ  
ΝΔΦ ΣΥΝΙ ΓΥΙΒΜΗΨ ΗΕΓΦΗΨ Α ΝΙΑ ΣΥΝΙ ΥΙ ΟΕΜΕΛΔΗΙ ΕΟΚΙΔΦ Γ ΘΙΧΧΙΘ  
ΠΕΞΖ Α ΖΑΘΨΥΔΙΗΙ ΥΙ ΛΦΓΑΝΙ ΗΑ ΘΦΥΖ ΧΕΠΔΦΜ ΗΖΛΑ ΥΙ ΟΕΘΑΔΖ ΚΕΖΔΙ  
ΖΑ ΛΕ ΓΥΙΒΜ ΧΕΖΝΖ ΧΑΓΑΚΗΨ Α ΝΖ ΥΙ ΝΙΑΨ ΘΑ ΖΧΑΖΑΝ ΛΕ ΧΝΙΚΙ ΥΧΖΟ  
ΦΗΨ ΔΦΛΦ ΟΕΛΔΙ ΝΙΕΚΦΙ ΛΕΧΝΕΚΑ ΓΔΑΒΜΑ ΟΑΝΚΦΝΙ ΣΥΝΙΔΦ ΟΚΨ ΒΔΕ  
ΓΙΧΙΘ ΠΙΖ ΘΑΗΝΑΖΦΙ ΠΙΖ ΝΕΖΜΨ ΟΕ ΛΨΗΑΘΦΒΙ Α ΠΙΖ ΥΘΨΥΔΖ ΟΚΕ ΜΖΘΕ  
Κ ΠΖΛΙΝΙ ΥΙ ΗΑ ΝΨ ΧΕΠΔΦΜΨ ΛΦΓΑΝ ΝΖΟΙ Α ΠΙΖΘΨΥΔΙΗΧΕΓΦΝΙ ΝΚΙΠΛ  
ΑΖ ΛΕ ΟΕΔΙΛΗΙ Α ΟΑΧ ΥΙ ΖΓΙΛΗΝΙ Α ΟΖΣΛΙΝΙ Χ ΕΠΙΛΖ ΘΑΘ ΛΖΓΕΛΗΙ ΟΕΛΙ  
ΖΚΙΗΦ ΖΙ ΛΕ ΝΙΝΕ ΟΚΓΙ ΥΧΖΟΦΗΨ ΖΑΚΑΖΖΣΙ ΛΕΧΝΕΚ ΓΔΑΒΜ ΝΑΧΙ ΘΗΙ Θ  
ΨΥΔΦΘ ΖΙ ΗΙΗΦ Γ ΟΚΑΓΖ Ε ΜΖΘΕΚΖ Α Ε ΝΙ ΛΨΗΑΘΦΒΙ ΗΠΠΖΛΙΘΙ ΘΔΖΓΦΝ  
ΑΔΙ ΝΕ ΖΙ ΘΦ ΖΟΦΚΑ ΘΑΗΝΑΖΦΦ ΧΛΨΖ ΓΦ ΖΙ ΥΙ ΘΦ ΟΕΓΙΛΔΕ ΥΟΚΑΓΗΙ,,

- a) Jako první krok přiřadíme každému symbolu jedno písmeno z naší abecedy, abychom mohli zanalyzovat. Nejsnazší postup je začít u A, a pokračovat přes B.... až do Z. Výsledkem bude:

„ABCEDFG HIJAJ KAL GUIBMHA NA OKFKEGHAHF A OELEPIHUNGF CNIKYJF LECNEK GDABM OKEODINA UGI NIJOIKAJIHNHF KIBF VZHAGAJ ZI HA NEJ HAZEKHIJ OKFCDALV U CAGAKHEV BDEGICIJ A JFUEV CEPDFM HIBE SI DZI HA HIJ AUOEH OKFPDFZHI VCAZAN SACYJ BDEGICIJ SI UANVKHFH LECNEK GDABM UF NENFZ KEZLIDFD DFLF OELDI NEME SAC UI BMEGASF G OEDEOKAZLHI CAGAKHI JASDFD OKIL UIPEV JFUV CEPDFM OKILUNAGNI UF DVXVUHF CAGAKHV ZA HILIDHFME ELOEDILHI GIHCV SI CKAUHY LIH A MEUNV G CAGAKHI SI JADE VZ SUNI UI HAUHFLADF OKIBINDF SUNI GUIBMHY HEGFHY A NIL SUNI UI OEMELDHI EOKIDF G JICCIJ PEXV A ZAJYUDIHI UI LFGANI HA JFUV CEPDFM HVLA UI OEJADV KEZDIZA LE GUIBM CEVNV CAGAKHY A NV UI NILY JA VCAZAN LE CNIKI UCVOFHY DFLF OELDI NIEKFI LECNEKA GDABMA OANKFNI SUNIDF OKY BDEGICIJ PIZ QAHNAZFI PIZ NEVMY OE LYHAJFBI A PIZ UJYUDV OKE MVJEK PVLINI UI HA NY CEPDFMY LFGAN NVOI A PIZJYUDIHCEGFNI NKIPA AZ LE OEDILHI A OAC UI ZGILHINI A OVSLINI C EPILV JAJ LVGELHI OELIZKIHF ZI LE NINE OKGI UCVOFHY ZAKAZVSI LECNEK GDABM NACI JHI JYUDFJ ZI HIHF G OKAGV E MVJEKV A E NI LYHAJFBI HIPVLIJI JDVGFN ADI NE ZI JF VOFKA QAHNAZFF CLYZ GF ZI UI JF OEGILDE UOKAGHI „

b) Nyní přijde na řadu frekvenční analýza. Doporučuji otevřít excelovský soubor: [Frekvenční analýza](http://pankun.webzdarma.cz/data/fa.xls) a prohlédnout si ho. (<http://pankun.webzdarma.cz/data/fa.xls>)

Do políčka F6 – s popisem Zkoumaný text nakopírujeme text, který jsme získali převodem znaků na písmena. (Bude to vypadat asi takto)

TEXT	Absolutní četnost	Relativní četnost	Vzorová četnost	Substituce
A			9,6	
B			1,8	
C			2,9	
D			3,8	
E			10,9	
F			0,2	
G			0,2	
H			2,5	
I			6,7	
J			2,3	
K			3,5	
L			5,7	
M			3,6	
N			5,9	
O			8,1	
P			3,1	
Q			0,0	
R			4,4	
S			5,6	
T			5,4	
U			3,6	
V			3,9	
W			0,1	
X			0,0	
Y			2,9	
Z			3,3	

**FREKVENČNÍ ANALÝZA**

**Zkoumaný text:**

ABCEDFG HIJAJ KAL GUIBMHA NA OKFKEGHAHF A OELEPIHUNGF CNIKYJF LECNEK GDABM OKEODINA UGI NIJOIKAJIHNHF KIBF VZHAGAJ ZI HA NEJ HAZEKHIJ OKFCDALV U CAGAKHEV BDEGICIJ A JFUEV CEPDFM HIBE SI DZI HA HIJ AUOEH OKFPDFZHI VCAZAN SACYJ BDEGICIJ SI UANVKHFH LECNEK GDABM UF NENFZ KEZLIDFD DFLF OELDI NEME SAC UI BMEGASF G OEDEOKAZLHI CAGAKHI JASDFD OKIL UIPEV JFUV CEPDFM OKILUNAGNI UF DVXVUHF CAGAKHV ZA HILIDHFME ELOEDILHI GIHCV SI CKAUHY LIH A MEUNV G CAGAKHI SI JADE VZ SUNI UI HAUHFLADF OKIBINDF SUNI GUIBMHY HEGFHY A NIL SUNI UI OEMELDHI EOKIDF G JICCIJ PEXV A ZAJYUDIHI UI LFGANI HA JFUV CEPDFM HVLA UI OEJADV KEZDIZA LE GUIBM CEVNV CAGAKHY A NV UI NILY JA VCAZAN LE CNIKI UCVOFHY DFLF OELDI NIEKFI LECNEKA GDABMA OANKFNI SUNIDF OKY BDEGICIJ

**Upravený text**

**Substituce**

Vlevo ve sloupci D jsou uvedeny vzorové četnosti výskytů znaků v Českém jazyce. A zmáčkněte tlačítko „Analyzuj!“

TEXT	Absolutní četnost	Relativní četnost	Vzorová četnost	Substituce	
A	85	5,0	9,6		<b>FREKVENČNÍ ANALÝZA</b>
B	17	1,0	1,8		
C	36	2,1	2,9		
D	43	2,5	3,8		
E	70	4,1	10,9		
F	57	3,4	0,2		
G	39	2,3	0,2		
H	57	3,4	2,5		
I	115	6,8	6,7		
J	38	2,2	2,3		
K	42	2,5	3,5		
L	43	2,5	5,7		
M	19	1,1	3,6		
N	51	3,0	5,9		
O	35	2,1	8,1		<b>Zkoumaný text:</b>
P	16	0,9	3,1		ABCEDFG HIJAJ KAL GUIBMHA NA OKFKEGHAHF A OELEPIHUNGF CNIKYJF
Q	2	0,1	0,0		LECNEK GDABM OKEODINA UGI NIJOIKAJIHNHF KIBF VZHAGAJ ZI HA NEJ
R	0	-	4,4		HAZEKHJ OKFCDALV U CAGAKHEV BDEGICIJ A JFUEV CEPDFM HIBE SI DZI HA
S	14	0,8	5,6		HIJ AUOEH OKFPDFZHI VCAZAN SACYJ BDEGICIJ SI UANVKHFH LECNEK GDABM
T	0	-	5,4		UF NENFZ KEZLIDFD DFLF OELDI NEME SAC UI BMEGASF G OEDEOKAZLHI
U	40	2,4	3,6		CAGAKHI JASDF OKIL UIPEV JFUV CEPDFM OKILUNAGNI UF DVXVUH CAGAKHV
V	39	2,3	3,9		ZA HILIDHFME ELOEDILHI GIHCV SI CKAUHY LIH A MEUNV G CAGAKHI SI JADE VZ
W	0	-	0,1		SUNI UI HAUHFLADF OKIBINDF SUNI GUIBMHY HEGFHY A NIL SUNI UI OEMELDHI
X	2	0,1	0,0		EOKIDF G JICCIJ PEXV A ZAJYUDIHI UI LFGANI HA JFUV CEPDFM HVLA UI
Y	20	1,2	2,9		OEJADV KEZDIZA LE GUIBM CEVNV CAGAKHY A NV UI NILY JA VCAZAN LE CNIKI
Z	31	1,8	3,3		UCVOFHY DFLF OELDI NIEKFI LECNEKA GDABMA OANKFNI SUNIDF OKY BDEGICIJ
					<b>Upravený text</b>
					abcdedfg hijaj kal guibmha na okfkeghahf a oelepihungf cnikyjf lecnec gdabm
					okeodina ugi nioikajihnhf kibf vzhagaj zi ha nej hazekhj okfcdalv u cagakhev
					bdegicij a jfuev cepdfm hibe si dzi ha hij auoeh okfpdfzhi vcazan sacyj
					bdegicij si uanvkfhf lecnec gdabm uf nenfz kezlidfd dflf oeldi neme sac ui
					bme gasf g oedeokazlhi cagakhi jasdf okil uipev jfuv cepdfm okilunagni uf
					dvxvuhf cagakhv za hilidhfme eloedilhi gihcv si ckauchy lih a meunv g cagakhi
					si jade vz suni ui hauhfladf okibindf suni guibmhy hegfhy a nil suni ui
					oemeldhi eokidf g jiccij pexv a zajyudihi ui lfgani ha jfuv cepdfm hvla ui
					oejadv kezdiza le guibm cevnu cagakhy a nv ui nily ja vcazan le cniki
					ucvofhy dflf oeldi niekfi lecneka gdabma oankfni sunidf oky bdegicij piz
					gahnazfi piz nevmv oe lvhaifbi a piz uivudy oke mviek pvlini ui ha nv
					<b>Substituce</b>

V políčku Upravený text se nám zpráva automaticky převede na malá písmena, odstraní se diakritika a další znaky, které nechceme.

Nyní přišel čas prozkoumat výsledky Frekvenční analýzy:

TEXT	Absolutní četnost	Relativní četnost	Vzorová četnost	Substituce
A	85	5,0	9,6	
B	17	1,0	1,8	
C	36	2,1	2,9	
D	43	2,5	3,8	
E	70	4,1	10,9	
F	57	3,4	0,2	
G	39	2,3	0,2	
H	57	3,4	2,5	
I	115	6,8	6,7	
J	38	2,2	2,3	
K	42	2,5	3,5	
L	43	2,5	5,7	
M	19	1,1	3,6	
N	51	3,0	5,9	
O	35	2,1	8,1	
P	16	0,9	3,1	
Q	2	0,1	0,0	
R	0	-	4,4	
S	14	0,8	5,6	
T	0	-	5,4	
U	40	2,4	3,6	
V	39	2,3	3,9	
W	0	-	0,1	
X	2	0,1	0,0	
Y	20	1,2	2,9	
Z	31	1,8	3,3	
<b>Počet znaků:</b>			<b>1695</b>	

Na první pohled jsou vidět rozdíly mezi četnostmi znaků v analyzovaném textu a vzorové četnosti. (např. znak „O“ je v textu obsažen 2%, kdežto v běžné řeči až 8,1%....)

Je načase všechny hodnoty srovnat podle četnosti. (v excelu nakopírujeme na další list a srovnáme) Výsledek bude vypadat takto:

TEXT	Relativní četnost	Vzorová abeceda	Vzorová četnost
I	6,8	E	10,9
A	5,0	A	9,6
E	4,1	O	8,1
F	3,4	I	6,7
H	3,4	N	5,9
N	3,0	L	5,7
D	2,5	S	5,6
K	2,5	T	5,4
L	2,5	R	4,4
U	2,4	V	3,9
G	2,3	D	3,8
V	2,3	M	3,6
J	2,2	U	3,6
C	2,1	K	3,5
O	2,1	Z	3,3
Z	1,8	P	3,1
Y	1,2	C	2,9
M	1,1	Y	2,9
B	1,0	H	2,5
P	0,9	J	2,3
S	0,8	B	1,8
Q	0,1	F	0,2
X	0,1	G	0,2
R	-	W	0,1
T	-	X	0,0
W	-	Q	0,0

Co nám to říká? Analýza říká, že znak „I“ v zašifrovaném textu odpovídá znaku „E“ v rozšifrované podobě, A odpovídá A, E odpovídá O .....

Nyní je třeba vyzkoušet, zda to funguje i v praxi.

Do sloupce E (Substituce) je třeba ručně přiřadit písmena podle výsledů analýzy. Je dobré začít několika nejpoužívanějšími znaky. ( Pro ukázkou doplním 6 nejčastějších.) Doplněná tabulka bude vypadat následovně:



analýza spletla, je dobré mezi sebou prohodit několik nejfrekventovanějších znaků, než dostaneme výsledek, který se nám bude zdát smysluplný. Horní buňka „Substitute“ kombinuje rozšifrovaná písmena (psaná Velkými písmeny) s původním textem. Druhá buňka ukazuje rozšifrovaný text + nahrazuje původní text znakem hvězdičky. Myslím, že nyní můžeme uhodnout několik dalších znaků a slov. (druhé slovo NEJAJ by mohlo být slovem NEMAM = J v zašifrované podobě odpovídá M) Slovo nEMoEkAMENnNI by mohlo být TEMPERAMENTNI = n – T, o – P, k – R,) ! Po každé změně v tabulce Substitute, je třeba znovu zmáčknout tlačítko „Substitute !“

Nyní výsledky vypadají takto:

Substitute ***	
A**O*I*	NEMAM RA* **E**NA TA PRIRO*NANI A PO*O*EN*T*I *TER*MI *O*TOR
**A**	PROP*ETA **E TEMPERAMENTNI RE*I **NA*AM *E NA TOM NA*ORNEM
PRI**A**	* *A*ARNO* **O*E*EM A MI*O* *O**I* NE*O *E **E NA NEM
A*PON	PRI**I*NE **A*AT *A**M **O*E*EM *E *AT*RNIN *O*TOR **A** *I TOTI*
RO**E*I*	*I*I PO**E TO*O *A* *E **O*A*I * PO*OPRA**NE *A*ARNE MA*I*I
PRE* *E*O*	MI** *O**I* PRE**TA*TE *I *****NI *A*ARN* *A NE*E*NI*O
O*PO*E*NE	*EN** *E *RA*N* *EN A *O*T* * *A*ARNE *E MA*O ** **TE *E
NA*NI*A*I	PRE*ET*I **TE **E**N* NO*IN* A TE* **TE *E PO*O**NE OPRE*I *
ME**EM	*O** A *AM***ENE *E *I*ATE NA MI** *O**I* N**A *E POMA**
RO**E*A	*O **E** *O*T* *A*ARN* A T* *E TE** MA **A*AT *O *TERE
***PIN*	*I*I PO**E TEORIE *O*TORA **A**A PATRITE **TE*I PR* **O*E*EM

Stejným způsobem pokračujeme dál, dokud nedoplníme matici. Finální podoba substitute znaků bude následující:

TEXT	Absolutní četnost	Relativní četnost	Vzorová četnost	Substituce
A	85	5,0	9,6	a
B	17	1,0	1,8	c
C	36	2,1	2,9	k
D	43	2,5	3,8	l
E	70	4,1	10,9	o
F	57	3,4	0,2	i
G	39	2,3	0,2	v
H	57	3,4	2,5	n
I	115	6,8	6,7	e
J	38	2,2	2,3	m
K	42	2,5	3,5	r
L	43	2,5	5,7	d
M	19	1,1	3,6	h
N	51	3,0	5,9	t
O	35	2,1	8,1	p
P	16	0,9	3,1	b
Q	2	0,1	0,0	f
R	0	-	4,4	g
S	14	0,8	5,6	j
T	0	-	5,4	q
U	40	2,4	3,6	s
V	39	2,3	3,9	u
W	0	-	0,1	w
X	2	0,1	0,0	x
Y	20	1,2	2,9	y
Z	31	1,8	3,3	z
Počet znaků:			1695	

a výsledný text:

Substituce
ACKOLIV NEMAM RAD VSECHNA TA PRIROVNANI A PODOBENSTVI KTERYMI DOKTOR VLACH PROPLETA SVE TEMPERAMENTNI RECI UZNAVAM ZE NA TOM NAZORNEM PRIKLADU S KAVARNOU CLOVEKEM A MISOU KOBLIH NECO JE LZE NA NEM ASPON PRIBLIZNE UKAZAT JAKYM CLOVEKEM JE SATURNIN DOKTOR VLACH SI TOTIZ ROZDELIL LIDI PODLE TOHO JAK SE CHOVAJI V POLOPRAZDNE KAVARNE MAJILI PRED SEBOU MISU KOBLIH PREDSTAVTE SI LUXUSNI KAVARNU ZA NEDELNIHO ODPOLEDNE VENKU JE KRASNY DEN A HOSTU V KAVARNE JE MALO UZ JSTE SE NASNIDALI PRECETLI JSTE VSECHNY NOVINY A TED JSTE SE POHODLNE OPRELI V MEKKEM BOXU A ZAMYSLENE SE DIVATE NA MISU KOBLIH NUDA SE POMALU ROZLEZA DO VSECH KOUTU KAVARNY A TU SE TEDY MA UKAZAT DO KTERE SKUPINY LIDI PODLE TEORIE DOKTORA VLACHA PATRITE JSTEJI PRY CLOVEKEM BEZ FANTAZIE BEZ

Snadné, že? ☺

c) Tipy a triky.

- Na adrese <http://www.mojepixwords.cz/napoveda/> funguje vyhledávání slov podle písmen. Prázdné znaky jsou nahrazovány hvězdičkami. Stačí tedy slovo nakopírovat z buňky obsahující písmena proložená hvězdičkami. (T6)

d) Jak to celé funguje? Soubor je ve formátu Excel a používá funkce VBA. (je třeba povolit) Soubor dávám k dispozici pro další úpravy a testování.

Přeji hodně zdaru s luštěním. V případě dotazů mě kontaktujte na emailu:  
[pankun@centrum.cz](mailto:pankun@centrum.cz)