

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ»
ім. Ігоря Сікорського
Кафедра системного проектування

РОЗРАХУНКОВО-ГРАФІЧНА РОБОТА
з дисципліни
"Теорія інформації і кодування"
на тему: Програма автоматичного визначення
кової таблиці текстового файлу

Студента 2го курсу
групи ДА-61
Кравченко Богдана Євгеновича
Керівник доц., к.т.н. Капшук О.О.

Зміст

- Короткі відомості
- ASCII
- Windows-1251
- Unicode
- Версії Юнікод
- UTF-8
- UTF-16 і UTF32
- Розробка програми
- Інтерфейс програми
- Існуючі програми для перевірки кодування
- Тестування
- Висновок
- Список літератури

Мета роботи

Розробити програму автоматичного визначення
кодової таблиці текстового файлу

Короткі відомості



- Безліч символів, за допомогою яких записується текст, називається **алфавітом**.
- Число символів в алфавіті - це його **потужність**.
- Формула визначення кількості інформації: $N = 2^b$, де N – потужність алфавіту (кількість символів), b - кількість біт (інформаційна вага символу).
- В алфавіт потужністю 256 символів можна помістити практично всі необхідні символи. Такий алфавіт називається **достатнім**.
- Оскільки $256 = 2^8$, то вага 1 символу - 8 біт.
- Одиниці виміру 8 біт присвоїли назву 1 байт:
- 1 байт = 8 біт.
- **Двійковий код кожного символу в комп'ютерному тексті займає 1 байт пам'яті.**

ASCII

```
!"#$%&'()*+,-./  
0123456789:;<=>?  
@ABCDEFGHIJKLMNO  
PQRSTUVWXYZ[\]^_  
`abcdefghijklmnopqrstuvwxyz{|}~
```

ASCII (англ. American Standard Code for Information Interchange) - американський стандартний код для обміну інформацією.

ASCII представляє собою кодування для представлення десяткових цифр, латинської та національного алфавітів, розділових знаків і керуючих символів. Спочатку розроблена як 7-бітна, з широким розповсюдженням 8-бітного байта ASCII стала сприйматися як половина 8-бітної.

Таблиця ASCII

Dec	Hx	Oct	Char	Dec	Hx	Oct	Html	Chr	Dec	Hx	Oct	Html	Chr	Dec	Hx	Oct	Html	Chr
0	0	000	NUL (null)	32	20	040	 	Space	64	40	100	@	@	96	60	140	`	`
1	1	001	SOH (start of heading)	33	21	041	!	!	65	41	101	A	A	97	61	141	a	a
2	2	002	STX (start of text)	34	22	042	"	"	66	42	102	B	B	98	62	142	b	b
3	3	003	ETX (end of text)	35	23	043	#	#	67	43	103	C	C	99	63	143	c	c
4	4	004	EOT (end of transmission)	36	24	044	$	\$	68	44	104	D	D	100	64	144	d	d
5	5	005	ENQ (enquiry)	37	25	045	%	%	69	45	105	E	E	101	65	145	e	e
6	6	006	ACK (acknowledge)	38	26	046	&	&	70	46	106	F	F	102	66	146	f	f
7	7	007	BEL (bell)	39	27	047	'	'	71	47	107	G	G	103	67	147	g	g
8	8	010	BS (backspace)	40	28	050	(	(	72	48	110	H	H	104	68	150	h	h
9	9	011	TAB (horizontal tab)	41	29	051	)	)	73	49	111	I	I	105	69	151	i	i
10	A	012	LF (NL line feed, new line)	42	2A	052	*	*	74	4A	112	J	J	106	6A	152	j	j
11	B	013	VT (vertical tab)	43	2B	053	+	+	75	4B	113	K	K	107	6B	153	k	k
12	C	014	FF (NP form feed, new page)	44	2C	054	,	,	76	4C	114	L	L	108	6C	154	l	l
13	D	015	CR (carriage return)	45	2D	055	-	-	77	4D	115	M	M	109	6D	155	m	m
14	E	016	SO (shift out)	46	2E	056	.	.	78	4E	116	N	N	110	6E	156	n	n
15	F	017	SI (shift in)	47	2F	057	/	/	79	4F	117	O	O	111	6F	157	o	o
16	10	020	DLE (data link escape)	48	30	060	0	0	80	50	120	P	P	112	70	160	p	p
17	11	021	DC1 (device control 1)	49	31	061	1	1	81	51	121	Q	Q	113	71	161	q	q
18	12	022	DC2 (device control 2)	50	32	062	2	2	82	52	122	R	R	114	72	162	r	r
19	13	023	DC3 (device control 3)	51	33	063	3	3	83	53	123	S	S	115	73	163	s	s
20	14	024	DC4 (device control 4)	52	34	064	4	4	84	54	124	T	T	116	74	164	t	t
21	15	025	NAK (negative acknowledge)	53	35	065	5	5	85	55	125	U	U	117	75	165	u	u
22	16	026	SYN (synchronous idle)	54	36	066	6	6	86	56	126	V	V	118	76	166	v	v
23	17	027	ETB (end of trans. block)	55	37	067	7	7	87	57	127	W	W	119	77	167	w	w
24	18	030	CAN (cancel)	56	38	070	8	8	88	58	130	X	X	120	78	170	x	x
25	19	031	EM (end of medium)	57	39	071	9	9	89	59	131	Y	Y	121	79	171	y	y
26	1A	032	SUB (substitute)	58	3A	072	:	:	90	5A	132	Z	Z	122	7A	172	z	z
27	1B	033	ESC (escape)	59	3B	073	;	;	91	5B	133	[	[	123	7B	173	{	{
28	1C	034	FS (file separator)	60	3C	074	<	<	92	5C	134	\	\	124	7C	174	|	
29	1D	035	GS (group separator)	61	3D	075	=	=	93	5D	135	]	]	125	7D	175	}	}
30	1E	036	RS (record separator)	62	3E	076	>	>	94	5E	136	^	^	126	7E	176	~	~
31	1F	037	US (unit separator)	63	3F	077	?	?	95	5F	137	_	_	127	7F	177		DEL

Windows-1251

Windows-1251 (також вживаються назви **Win1251**, **CP1251**) — кодування символів, що є стандартним 8-бітовим кодуванням для всіх локалізованих українських і російських версій Microsoft Windows. Користується досить великою популярністю. Була створена на базі кодувань, що використалися в ранніх «саморобних» русифікаторах Windows в 1990—1991 рр. спільно представниками «Параграфа», «Діалогу» і російського відділення Microsoft. Початковий варіант кодування помітно відрізнявся від сучасного, приведеного нижче в таблиці (зокрема, там було значне число «білих плям»).

Таблиця Windows-1251

	.0	.1	.2	.3	.4	.5	.6	.7	.8	.9	.A	.B	.C	.D	.E	.F
8.	Ъ 402	Ѓ 403	, 201A	ѓ 453	„ 201E	... 2026	† 2020	‡ 2021	€ 20AC	% 2030	Љ 409	< 2039	Њ 40A	Ќ 40C	Ѓ 40B	Ц 40F
9.	ђ 452	‘ 2018	’ 2019	“ 201C	” 201D	• 2022	— 2013	— 2014		™ 2122	Ў 459	> 203A	Њ 45A	Ќ 45C	ћ 45B	ц 45F
A.		Ў 40E	ў 45E	Ј 408	Ѡ A4	Ѓ 490	Ї A6	§ A7	Ё 401	© A9	Є 404	« AB	¬ AC		® AD	Ї 407
B.	° B0	± B1	І 406	і 456	г 491	μ B5	Ѓ B6	· B7	ё 451	№ 2116	є 454	» BB	ј 458	Ѕ 405	s 455	ї 457
C.	А 410	Б 411	В 412	Г 413	Д 414	Е 415	Ж 416	З 417	И 418	Й 419	К 41A	Л 41B	М 41C	Н 41D	О 41E	П 41F
D.	Р 420	С 421	Т 422	У 423	Ф 424	Х 425	Ц 426	Ч 427	Ш 428	Щ 429	Ъ 42A	Ы 42B	Ь 42C	Э 42D	Ю 42E	Я 42F
E.	а 430	б 431	в 432	г 433	д 434	е 435	ж 436	з 437	и 438	й 439	к 43A	л 43B	м 43C	н 43D	о 43E	п 43F
F.	р 440	с 441	т 442	у 443	ф 444	х 445	ц 446	ч 447	ш 448	щ 449	ъ 44A	ы 44B	ь 44C	э 44D	ю 44E	я 44F

Має три недоліки:

- мала (рядкова) буква «я» має код 0xFF (255 в 10-овій системі). Вона є «винуватицею» ряду несподіваних проблем в програмах без підтримки чистого 8-го біту.
- відсутні символи псевдографіки.
- при сортуванні в алфавітному порядку літери не йдуть підряд, оскільки між літерами ŷŸієЄїґґёЁ і основним блоком літер йдуть спецсимволи.

Unicode



Юнікод (англ. Unicode) - стандарт кодування символів, що включає в себе знаки майже всіх письмових мов світу. В даний час стандарт є домінуючим в Інтернеті. Стандарт запропонований в 1991 році некомерційною організацією «Консорціум Юнікоду» (англ. Unicode Consortium, Unicode Inc.). Застосування цього стандарту дозволяє закодувати дуже велике число символів з різних систем писемності: в документах, закодованих за стандартом Юнікод, можуть бути сусідами китайські ієрогліфи, математичні символи, букви грецького алфавіту, латиниці і кирилиці, символи музичної нотної нотації, при цьому стає непотрібним переключення кодових сторінок.

Стандарт складається з двох основних частин: універсального набору символів (англ. Universal character set, UCS) і сімейства кодувань (англ. Unicode transformation format, UTF). Універсальний набір символів перераховує допустимі за стандартом Юнікод символи і привласнює кожному символу код у вигляді невід'ємного цілого числа, що записується зазвичай в шістнадцятковій формі з префіксом U +, наприклад, U + 040F. Сімейство кодувань визначає способи перетворення кодів символів для передачі в потоці або в файлі. Коди в стандарті Юнікод розділені на кілька областей. Область з кодами від U + 0000 до U + 007F містить символи набору ASCII, і коди цих символів збігаються з їх кодами в ASCII. Далі розташовані області символів інших систем писемності, знаки пунктуації та технічні символи. Частина кодів зарезервована для використання в майбутньому. Під символи кирилиці виділені області знаків з кодами від U + 0400 до U + 052F, від U + 2DE0 до U + 2DFF, від U + A640 до U + A69F (див. Кирилиця в Юнікоде).

Способи представлення

Юнікод має кілька форм представлення (англ. Unicode transformation format, UTF): UTF-8, UTF-16 (UTF-16BE, UTF-16LE) і UTF-32 (UTF-32BE, UTF-32LE). Була розроблена також форма подання UTF-7 для передачі по семибітним каналах, але через несумісність з ASCII вона не набула поширення і не включена в стандарт.

Версії Юнікода



UTF-8

UTF-8 - уявлення Юнікода, що забезпечує найбільшу компактність і зворотну сумісність з 7-бітної системою ASCII; текст, що складається тільки з символів з номерами менше 128, при записі в UTF-8 перетворюється в звичайний текст ASCII і може бути відображений будь-якою програмою, що працює з ASCII; і навпаки, текст, закодований 7-бітної ASCII може бути відображений програмою, призначеної для роботи з UTF-8. Решта символів Юнікоду зображуються послідовностями довжиною від 2 до 4 байт, в яких перший байт завжди має маску 11xxxxxx, а решта - 10xxxxxx. В UTF-8 не використовуються сурогатні пари.

UTF-16 і UTF-32

- UTF-16 - кодування, що дозволяє записувати символи Юнікоду в діапазонах $U + 0000 \dots U + D7FF$ і $U + E000 \dots U + 10FFFF$ (загальною кількістю 1 112 064). При цьому кожен символ записується одним або двома словами (сурогатна пара). Кодування UTF-16 описана в додатку Q до міжнародного стандарту ISO / IEC 10646, а також їй присвячений документ IETF RFC 2781 під назвою «UTF-16, an encoding of ISO 10646».
- UTF-32 - спосіб представлення Юнікоду, при якому кожен символ займає рівно 4 байта. Головна перевага UTF-32 перед кодуваннями змінної довжини полягає в тому, що символи Юнікод в ній безпосередньо індексованих, тому знайти символ за номером його позиції в файлі можна надзвичайно швидко, і отримання будь-якого символу n -ї позиції при цьому є операцією, що займає завжди однакове час. Це також робить заміну символів в рядках UTF-32 дуже простий. Навпаки, кодування зі змінною довжиною вимагають послідовного доступу до символу n -ї позиції, що може бути дуже витратною за часом операцією. Головний недолік UTF-32 - це неефективне використання простору, так як для зберігання будь-якого символу використовується чотири байти. Символи, що лежать за межами нульовий (базової) площині кодового простору, рідко використовуються в більшості текстів. Тому подвоєння, в порівнянні з UTF-16, займаного рядками в UTF-32 простору, часто не виправдано.

Розробка програми






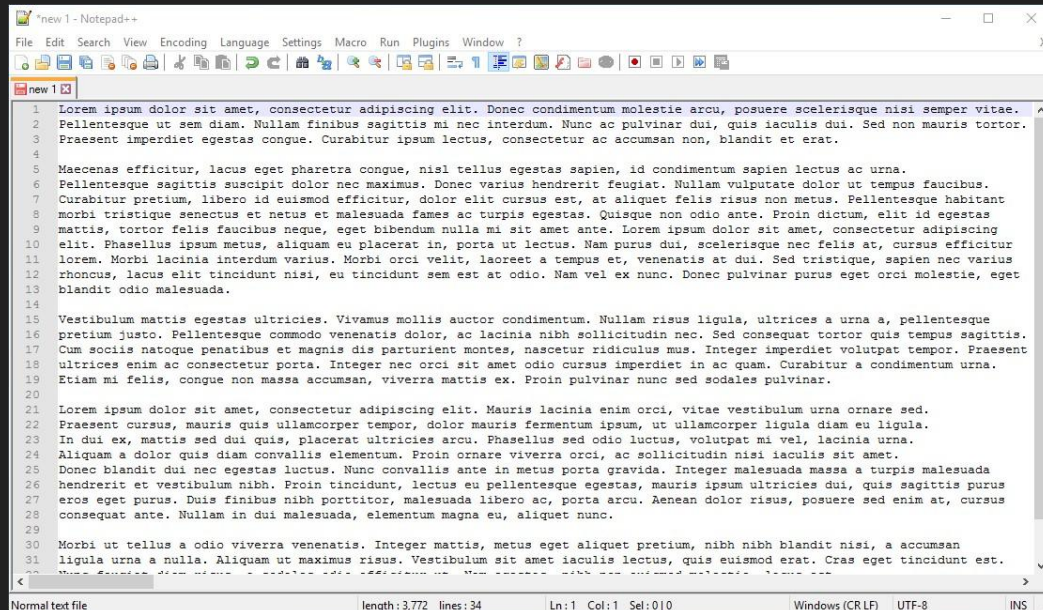
Рис. Алгоритм

Інтерфейс програми



Існуючі програми для перевірки кодування

NotePad++



<http://foxtools.ru/Text>

Универсальный декодер текста

Укажите текст, кодировку которого необходимо определить или изменить

-- выберите читаемый вариант из списка --

Исходная кодировка:

неизвестно

Определить Windows-1251 KOI8-R KOI8-U GB2312 UTF-8

Конечная кодировка:

неизвестно

Определить Windows-1251 KOI8-R KOI8-U GB2312 UTF-8

Автоматически определять:

только популярные кодировки все кодировки

Отправить

Очистить форму

Тестування програми

File name	Створена програма	Онлайн тест
euc.txt	EUC-JP	ISO-2022-JP
iso2022jp.txt	ISO-2022-JP	Shift-JIS
shiftjis.txt	Shift-JIS	EUC-JP
utf8.txt	UTF-8	UTF-8
utf8n.txt	UTF-8	UTF-8
utf16le.txt	UTF-16LE	UTF-16LE

Висновок

При виконанні розрахунково-графічної роботи було розглянуто кодування файлів. Було описано основні кодування текстових файлів.

У процесі виконання було розроблено програму, що реалізує автоматичне визначення кодової таблиці текстового файлу. Було виконано ряд тестів, які підтвердили правильність роботи програми(правильність визначення кодування текстового файлу)

Список літератури

- Вернер.М. Основы кодирования. Учебник для ВУЗов. Москва: Техносфера. 2004. – 288с.
- Dave Tomas, Endi Hat — The Pragmatic Programmer, 1999
- https://ru.wikibooks.org/wiki/Кодирование_текста
- <http://school497.ru/download/u/02/les10/les.html>
- <https://uk.wikipedia.org/wiki/Windows-1251>
- <https://uk.wikipedia.org/wiki/KOI-8>
- <https://uk.wikipedia.org/wiki/CP866>
- <https://ru.wikipedia.org/wiki/MacCyrillic>
- <https://uk.wikipedia.org/wiki/UTF-8>
- <https://uk.wikipedia.org/wiki/UTF-16>

Дякую за увагу!