

Reprezentacja symboli w
komputerze.

Znaki alfabetu i łańcuchy
znakowe.

- 7 bitów, liczby z zakresu 0-127
- litery (alfabet angielski) [a-zA-Z]
- cyfry [0-9],
- znaki przestankowe, np. , . ; '
- inne symbole drukowalne, np. * ^ \$
- białe znaki: spacja, tabulacja, ...
- polecenia sterujące: znak nowej linii \n, nowej strony, koniec tekstu, koniec transmisji,...
- 8-bitowe rozszerzenia ASCII: cp1250, latin2, ...

USASCII code chart

b7 b6 b5					0 0 0 0 1 0 1 1 0 1 1 0 1 1								
b4 b3 b2 b1					Column Row								
b4 b3 b2 b1					0	1	2	3	4	5	6	7	
0	0	0	0	0	NUL	DLE	SP	0	@	P	\	p	
0	0	0	0	1	SOH	DC1	!	1	A	Q	a	q	
0	0	0	1	0	2	STX	DC2	"	2	B	R	b	r
0	0	1	1	1	3	ETX	DC3	#	3	C	S	c	s
0	1	0	0	0	4	EOT	DC4	\$	4	D	T	d	t
0	1	0	1	1	5	ENQ	NAK	%	5	E	U	e	u
0	1	1	0	0	6	ACK	SYN	&	6	F	V	f	v
0	1	1	1	1	7	BEL	ETB	'	7	G	W	g	w
1	0	0	0	0	8	BS	CAN	(	8	H	X	h	x
1	0	0	1	1	9	HT	EM	)	9	I	Y	i	y
1	0	1	0	0	10	LF	SUB	*	:	J	Z	j	z
1	0	1	1	1	11	VT	ESC	+	;	K	[	k	{
1	1	0	0	0	12	FF	FS	,	<	L	\	l	
1	1	0	1	1	13	CR	GS	-	=	M	]	m	}
1	1	1	0	0	14	SO	RS	.	>	N	^	n	~
1	1	1	1	1	15	SI	US	/	?	O	_	o	DEL

- typ char, 1 bajt, liczba całkowita $[-128, 127]$
- **stała znakowa** - znak zapisany w apostrofach, np.:
 - 'A' to liczba 65,
 - 'A'+1 to liczba 66 (kod litery 'B'),
 - nowy wiersz '\n' to liczba 10,
 - tabulator '\t' to liczba 9,
 - znak '\0' ma wartość 0
 - powrót karetki \r (w MS Windows koniec linii to \r\t)
 - znaki o specjalnym zapisie:
 - ukośnik w lewo '\\',
 - apostrof '\'',
 - cudzysłów '\"',
 - znak zapytania '\?'
- 🖱️ man 7 ascii
- Uwaga: "A" nie jest pojedynczym znakiem lecz tablicą znaków!

```
1  #include<stdio.h>
2
3  int main()
4  {
5      char a;
6
7      printf("Podaj znak: ");
8      scanf("%c",&a);
9
10     printf("znak %c, dec %d, oct %o, hex %x\n",a,a,a,a);
11     return 0;
12 }
```

 char.c

WYKRYWANIE MAŁEJ LITERY

```
int islower(int x)
{
    if(x >= 'a' && x <= 'z' ) return 1;
    return 0;
}
```

ZAMIANA MAŁEJ LITERY NA DUŻĄ

```
int toupper(int x)
{
    if( islower(x) ) x = x + 'a' - 'A';
    return x;
}
```

Plik nagłówkowy: `ctype.h`

KLASYFIKACJA ZNAKÓW

- `isalnum` - litera alfabetu lub cyfra [A-Za-z0-9]
- `isalpha` - litera alfabetu [A-Za-z]
- `islower`, `isupper` - mała / duża litera alfabetu
- `isdigit` - cyfra
- `isgraph` - znaki drukowalne (ze spacją)
- `isspace` - znaki białe
- `isprint` - znaki drukowalne (bez spacji)
- `ispunct` - znaki przestankowe (drukowalne bez liter i cyfr)

MANIPULACJE NA ZNAKACH

- `tolower` , `toupper` - zamiana wielkości liter alfabetu

PRZYKŁADY W C: ZAMIANA WIELKOŚCI ZNAKÓW

```
1  #include <stdio.h>
2  #include <ctype.h>
3
4  int main()
5  {
6      int a;
7
8      do
9      {
10         a=getchar();
11         putchar(toupper(a));
12     }while( a != EOF );
13
14     return 0;
15 }
```

 toupper2.c

- funkcja `getchar()`
zwraca pojedynczy znak
ze standardowego wejścia
lub EOF
- funkcja `putchar()`
wypisuje znak
- EOF - koniec pliku
(*end of file*)
- `toupper2 < plik.txt`
- EOF w terminalu:
CTRL+Z (Windows)
CTRL+D (Unix/Linux)

8 BITOWE STRONY KODOWE

- **Strona kodowa:** kodowanie binarne znaków pisarskich
- Polskie ogonki, 8 bitowe rozszerzenia ASCII:
 - ☞ ISO 8859-2 (latin2), alfabet łaciński dla Europy środkowej i wschodniej, UNIX/GNU Linux
 - ☞ CP-1250, języki środkowoeuropejskie, MS Windows
 - ☞ CP-852, MS DOS
- ☞ Kodowanie polskich znaków diakrycznych

- **Unicode** - standard z założenia obejmujący wszystkie języki świata (obecnie ponad 110k znaków ze 100 grup językowych).
- Określa przydział przestrzeni numeracyjnej poszczególnym grupom znaków
- Kodowanie znaków: UCS (Universal Character Set), UTF (Unicode Transformation Format), UTF-8, UTF-16, UTF-32
- UTF-8 - znaki kodowane za pomocą 1, 2, 3 bajtów
- Każdy tekst w ASCII jest tekstem w UTF-8
- Znaki ASCII od 0 do 127 są mapowane jako jeden bajt.
- Znaki spoza ASCII (np. polskie znaki) są mapowane jako dwa bajty (lub więcej).
- Ten sam znak można zapisać na kilka sposobów - wybieramy najkrótszy zapis.

- **Łańcuch** (*string*) - skończony ciąg symboli alfabetu
- W języku C brak typu `string`, występuje w C++
- Łańcuch to tablica zawierająca ciąg znaków zakończony znakiem `\0`

A	l	a		m	a		k	o	t	a	\0
---	---	---	--	---	---	--	---	---	---	---	----

- Dostęp do znaku jak w tablicach: `t[i]`
- Stała napisowa (literał znakowy): `"Ala ma kota"`
- stała znakowa `'A'` to liczba 65
- stała napisowa `"A"` to tablica

A	\0
---	----

PRZYKŁAD W C

```
#include<stdio.h>

int main()
{
    char *s1="nieciekawy fragment tekstu.";
    char s2[]="Ala ma kota";

    s1[0]='N';
    s2[0]='E';

    printf(s1);
    printf(" %s\n",s2);

    printf("\nBardzo %s\n", s1+3);

    return 0;
}
```

s1 to stały napis

Źle!

```
scanf("%s",...);
```

```
#include<stdio.h>
int main()
{
    char text[10];
    scanf("%s", text);
}
```

- niebezpieczeństwo przepełnienia tablicy
- `scanf("%10s",text);`
- wczyta tylko pierwszy wyraz, nie wczyta całego łańcucha z odstępami: "Ala ma kota"

```
char *gets(char *s);
```

- funkcja `gets()` czyta linię tekstu ze standardowego wejścia i umieszcza ją w tablicy `s`
- Uwaga: brak możliwości zabezpieczenia się przez przepełnieniem tablicy

```
#include<stdio.h>
int main()
{
    char text[10];
    gets(text);
}
```

```
char *fgets(char *s, int n, FILE *f);
```

- czyta linię tekstu, ale nie więcej niż `n` znaków, ze strumienia `f` i umieszcza tekst w tablicy `s`
- obowiązkowe podanie parametru `n`
- standardowy strumień wejściowy to `stdin`

```
#include<stdio.h>
int main()
{
    char text[10];
    fgets(text, 10, stdin);
}
```

PODSTAWOWE OPERACJE NA ŁAŃCUCHACH

- plik nagłówkowy `string.h`
- długość łańcucha
`int strlen(const char *s);`
- łączenie dwóch łańcuchów
`char *strcat(char *dest, const char *src);`
- porównywanie łańcuchów
`int strcmp(const char *s1, const char *s2);`
- kopiowanie łańcuchów
`char *strcpy(char *dest, const char *src);`
- wyszukiwanie wzorca
`char *strstr(const char *napis, const char *wzor);`

WYSZUKIWANIE WZORCA

Problem: wyszukiwanie podciągu (*pattern matching*).

W ciągu $\mathcal{T}$ znajdź wystąpienie wzorca $\mathcal{W}$.

Tekst $\mathcal{T}$ = "programowanie"

p	r	o	g	r	a	m	o	w	a	n	i	e	\0
---	---	---	---	---	---	---	---	---	---	---	---	---	----

Wzorzec $\mathcal{W}$ = "gra"

g	r	a	\0
---	---	---	----

Algorytm 1 Naiwne wyszukiwanie wzorca

Dane wejściowe: łańcuch znaków $\mathcal{T}$, wzorzec $\mathcal{W}$

Wynik: pozycja tekstu $\mathcal{W}$ w $\mathcal{T}$ lub wartość -1, gdy brak

- 1: **dla każdego** $i = 0, 1, 2, \dots, |\mathcal{T}| - |\mathcal{W}|$ **wykonuj**
 - 2: $k \leftarrow 0$
 - 3: **dopóki** $\mathcal{T}[i + k] = \mathcal{W}[k]$ **i** $k < |\mathcal{W}|$ **wykonuj**
 - 4: $k \leftarrow k + 1$
 - 5: **jeżeli** $k = |\mathcal{W}|$ **wykonaj**
 - 6: **zwróć** i
 - 7: **zwróć** -1
-


$|\mathcal{W}|$ oznacza długość łańcucha $\mathcal{W}$

```
1  int strindex(char t[], char w[])
2  {
3      int i, k;
4
5      i=0;
6      while(t[i] != '\0')
7      {
8          k=0;
9          while(t[i+k]==w[k] && w[k] != '\0')
10             k = k + 1;
11          if(w[k]=='\0') return i;
12          i = i + 1;
13      }
14      return -1;
15 }
```

ALGORYTM NAIWNY

Tekst $\mathcal{T}$ = "programowanie"

Wzorzec $\mathcal{W}$ = "mowa"




UPROSZCZONY ALGORYTM BOYERA-MOORE'A

Tekst $\mathcal{T}$ = "programowanie"

Wzorzec $\mathcal{W}$ = "mowa"

'o' występuje we wzorcu na pozycji 1
przesunięcie okna o $j-1 = 2$



'g' nie występuje we wzorcu
przesunięcie okna o $j+1 = 4$

TABLICA PRZESUNIĘĆ

- informacja o tym czy znak występuje we wzorcu
- rozmiar tablicy odpowiada liczbie znaków danego alfabetu, dla kodu ASCII wystarczy 128 elementów
- przechowuje pozycję ostatniego wystąpienia znaku we wzorcu lub -1 gdy znak nie występuje
- $tp[w[k]] = k$
- przesunięcie okna o wartość $\max(k - tp[w[k]], 1)$

TABLICA PRZESUNIĘĆ

```
1 void utworz_tp(int tp[] , char w[])
2 {
3     int i=0;
4
5     while(i<128)
6     {
7         tp[i]=-1;
8         i=i+1;
9     }
10
11     i=0;
12     while(w[i] != '\0')
13     {
14         tp[w[i]]=i;
15         i=i+1;
16     }
17 }
```

Algorytm 2 Uproszczony algorytm Boyera-Moore'a

Dane wejściowe: łańcuch znaków $\mathcal{T}$, wzorzec $\mathcal{W}$

Wynik: pozycja tekstu $\mathcal{W}$ w $\mathcal{T}$ lub wartość -1, gdy brak

- 1: $\mathcal{P} \leftarrow \text{utworz_tp}(\mathcal{W})$ ▷ tworzenie tablicy przesunięć
 - 2: $i \leftarrow 0$
 - 3: **dopóki** $i \leq |\mathcal{T}| - |\mathcal{W}|$ **wykonuj**
 - 4: $k \leftarrow |\mathcal{W}|$ ▷ porównywanie od tyłu
 - 5: **dopóki** $k \geq 0$ **i** $\mathcal{T}[i + k] = \mathcal{W}[k]$ **wykonuj**
 - 6: $k \leftarrow k - 1$
 - 7: **jeżeli** $k = -1$ **wykonaj**
 - 8: **zwróć** i
 - 9: **w przeciwnym wypadku**
 - 10: $i \leftarrow i + \max(1, k - \mathcal{P}[\text{kod}(\mathcal{T}[i + k])])$
 - 11: **zwróć** -1
-

gdzie $\text{kod}(x)$ oznacza kod liczbowy znaku x .

```

1  int strindex2(char t[], char w[])
2  {
3      int i, k, z, tl, wl;
4      int tp[128];
5
6      utworz_tp(tp, w);
7      tl=strlen(t);
8      wl=strlen(w);
9
10     i=0;
11     while(i <= tl-wl)
12     {
13         k=wl-1;
14         while(k>=0 && t[i+k]==w[k] ) k=k-1;
15         if(k== -1) return i;
16         z=k-tp[t[i+k]];
17         if(z<1) z=1;
18         i = i + z;
19     }
20     return -1;
21 }

```

- Typ znakowy jest liczbą całkowitą
- Łańcuch to tablica znaków zakończona znakiem `'\0'`
- Stała znakowa w apostrofach `'A'`
- Stała napisowa w cudzysłowach `"A"` jest tablicą
- Dostęp do znaku `t[i]`
- `t == "napis"` tak nie wolno porównywać, trzeba znak po znaku

-  Linux Programmer's Manual
man 7 ascii unicode codepages iso_8859-2
<http://www.unix.com/man-page/>
-  Wikipedia:  Kodowanie polskich znaków diakrycznych
-  Jerzy Wałaszek, „*Algorytmy. Struktury danych.*”,
 Łańcuchy znakowe.
-  R.S. Boyer, J. Strother Moore, *A Fast String Searching Algorithm* Communications of the Association for Computing Machinery, 20(10), 1977, pp. 762-772.
www.cs.utexas.edu/~moore/publications/fstrpos.pdf