

2. Tecken och texter

Sven Gestegård Robertz
Datavetenskap, LTH

2015



Tecken

char

```
char ch = 'A';
```

sizeof(char) = 1 byte (ej 16-bitars tecken som i Java)

```
char c1, c2;
c1 = 'A';
c2 = 106; // Samma som 'j'
cout << c1 << c2 << '! ' << endl;
```

1 byte ej nödvändigtvis en oktett (8 bitar).

Strängar

Ordet "sträng" (eng:string) kan betyda två saker i C++.

standardklass i C++: std::string

```
string s = "Hej";
```

C-strängar: null-terminerad char[]

```
char str[] = "Hej";
```

C-strängar ("Teckenfält")

Lagring i minnet

▶ null-terminerad: tecknet \0 markerar slutet på strängen

```
char namn[] = "Nils"; // längd = 5 bytes
```

är ekvivalent med

```
char namn[] = {'N', 'i', 'l', 's', '\0'};
```

▶

adress	data
namn	N
namn+1	i
namn+2	l
namn+3	s
namn+4	\0

Access av element

```
cout << namn[1] << namn[3];
is
```

C-Strängar

char[] är inte samma som char *

Istället för deklarationen

```
char str[] = "12345";
```

ser man ofta

```
const char *str2 = "12345";
```

men

```
sizeof(str) == 6 // 6 element    sizeof(str2) == 8 //!!!!
for(char c: str) // OK!         for(char c: str2) // Error!
...                               ...
```

NB! Generellt: antal element i en array av T:

```
T array[] {...};
...
size_t n = sizeof(array)/sizeof(T);
```

Teckenkodning

- ▶ 7-bitars ASCII: fungerar i alla (icke-antika) system
- ▶ många inkompatibla 8-bitars-kodningar
- ▶ Unicode-standarden
 - ▶ UTF-8 - den vanligaste teckenkodningen
 - ▶ UTF-16 (char i Java)
 - ▶ UTF-32 - alla tecken är lika stora

UTF8: ett tecken representeras som en eller flera byte

- ▶ En UTF-8-kodad sträng kan lagras i en char[].
- ▶ 7-bitars ASCII-tecken lagras i en byte

wchar_t: C++ "multi-byte characters"

- ▶ C++-standarden specificerar inte storleken (jfr char i Java),
 - ▶ oftast 32 bitar (UTF-32 fungerar)
 - ▶ Microsoft C++: 16 bitar

Teckenkodning

Åttabitsars tecken i Windows

Två olika 8-bitars-tabeller

- ▶ ISO-8859-1 (Latin-1) (Se Appendix B)
 - ▶ Windows code page 28591 (ISO-8859-1) (Latin-1)
 - ▶ Windows code page 1252 (Windows Latin-1)
- ▶ 850 (IBM-ASCII): Används bara i DOS

Svenska tecken under Windows

Ändra kodning i konsolfönstret

```
#include <iostream>
#include <cstdlib>

using namespace std;

int main()
{
    system("chcp 1252 >nul 2>nul");

    char ch = '7';
    int code, val;
    code = ch;
    val = ch - '0';
    cout << "Siffran " << ch << " har koden " << code
         << " och värdet " << val << endl;
}
```

Svenska tecken under Windows

med `iodos.h`, se förra årets kurshemsida/extramaterial

```
#include <iostream>
#include "iodos.h"

using namespace std;

int main()
{
    dos_console();

    char ch = '7';
    int code, val;
    code = ch;
    val = ch - '0';
    cout << "Siffran " << ch << " har koden " << code
         << " och värdet " << val << endl;
}
```

Specialtecken

control characters, non-printable characters

Escape-sekvenser (s. 71 i boken)

```
\n (ASCIIkod 10 = newline, line feed, LF)
\a (ASCIIkod 7 = bell)
\t (ASCIIkod 9 = tab)
\r (ASCIIkod 13 = carriage return, "vagnretur", CR)
\b (ASCIIkod 8 = backspace)
\nnn (tecken med ASCIIkod nnn (oktalt))
\xnn (tecken med ASCIIkod nn (hexadecimalt))
\\ (backslash)
\" (citationstecken)
\' (apostrof)
```

Radslut inkompatibelt mellan olika system

Unix : LF

Windows : CR LF

Äldre mac : CR

Teckenhantering

In- och utmatning av tecken

```
char c;

cout << c // Skriver ut tecknet c
cout.put(c) // Skriver ut tecknet c

cin >> c // Läser in nästa icke-vita tecken till c
cin.get(c) // Läser in nästa tecken till c

cin.peek() // Returnerar nästa tecken som förblir oläst
cin.ignore() // Läser nästa tecken men slänger det
```

Inmatning

Exempel 1

```
#include <iostream>
using namespace std;
int main(){
    char namn[30];
    cout << "Vad heter du? ";
    cin >> namn;
    cout << "Hej, " << namn << "!" << endl;
}
```

Vid körning:

Vad Heter du? Lars Olof Persson
Hej, Lars!

Byt ut `cin >> namn` mot `cin.getline(namn,30)`.

`cin.getline(var,antal)` läser \leq antal tecken, inkl. null

Inmatning

Exempel 2

```
#include <iostream>
using namespace std;
// Kryptiskt program
char kod[33]="qwertyuiopasdfghjklzxcvbnm012345";
int main()
{
    char c;
    cout << "Avslutning sker med Ctrl-z" << endl;
    while (cin.get(c)) {
        cout << kod[c%32];
    }
    cout << endl;
}
```

Använder

```
istream& istream::get(char& c);
```

Inmatning Varnande exempel

Den lästa strängen får inte plats i `x`

Satserna

```
char z[] {"zzzz"};
char y[] {"yyyy"};
char x[5];

stringstream sin("aaaaaaaaaaaaaaaaa bbbbbb");
sin >> x;

cout << x << " : " << y << " : " << z << endl;
```

Ger vid körning (på min dator):

```
aaaaaaaaaaaaaaaaaaaa : aaa : zzzz
```

- ▶ C-strängar ger inget skyddsnet
- ▶ läsningen till `x` har skrivit över (en del av) `y`
- ▶ `getline()` är säkrare

Inmatning

Exempel 3

```
#include <iostream>
using namespace std;
int main()
{
    string s;
    int tal = 0;
    cout << "Ange ett tal: ";
    cin >> s;
    for (char ch : s) { // C++11
        tal = 10 * tal + ch - '0';
    }
    cout << "Talets värde: " << tal << endl;
}
```

C-strängar – Funktioner

In- och utmatning av tecken

```
#include <cstring> // Bibliotek att inkludera

strcpy(s,t) // Kopierar t till s
strncpy(s,t,n) // Variant med max n tecken

strcat(s,t) // Läger till t till slutet av s
strncat(s,t,n) // Variant med max n tecken

strlen(s) // Returnerar längden av s

strcmp(s,t) // Jämför s och t
strncmp(s,t,n) // Variant med max n tecken
// s<t, s==t, s>t ger resp. <0, =0, >0
```

Osäkra, undvik!

Initiering och tilldelning

Initiering

```
char s[4] = "abc"; // OK
char s[] = "abc"; // OK
char s[3] = "abc"; // Inte OK (pga \0)
```

Tilldelning

```
s = "def"; //Felaktigt!
s[0]='d'; s[1]='e'; s[2]='f'; // OK

// Bättre variant:
strncpy(s, "def", 4); // kräver #include <cstring>
```

Strängkopiering Varnande exempel

Satserna

```
char s[20];
strncpy(s, "abc", 4);
cout << s << endl;

strncpy(s, "kalle anka", 20);
cout << s << endl;

strncpy(s, "def", 3);
cout << s << endl;
```

ger utskriften

```
abc
kalle anka
defle anka
```

Satserna

```
int data[] {558646598, 65, 66};
char x[16];
char t[30] {"test"};

strncpy(x, "abcdefghijklmnop", 16);
strcpy(t,x);
cout << t << endl;
```

ger utskriften

```
abcdefghijklmnopFEL!A
```


Tänk på att

- ▶ `strncpy` måste ha plats till avslutande `\0`.
- ▶ `strcpy` kopierar tills den hittar ett `\0` i `src`.

Strängkopiering

Varnande exempel: förklaring

```
int data[]{558646598, 65, 66}; ▶ int data[] tolkas som char[].  
char x[16]; ▶ representation i minnet
```



Hexadecimal representation:

$$558646598_{10} = 214c4546_{16}$$

$$65_{10} = 41_{16}$$

Byte-ordning: *little-endian*

hex	ASCII	dec
46	F	70
45	E	69
4c	L	76
21	!	33
41	A	65
0	\0	0
0	\0	0
0	\0	0
...

Standardklassen `std::string`

Enklare hantering än med `char[]`:

- ▶ liknar `java.lang.String`
- ▶ har skyddsnet

Exempel

```
string s1("abc");  
string s2="def";  
string s3;  
  
cout << s3.size() << endl;                   0  
                                          4  
s3 = "ghij";  
cout << s3.size() << endl;                   16  
                                          26  
                                          abcde fghijklmnopqrstuvwxyz  
s3 = s1 + s2 + s3 + "klmnop";  
cout << s3.size() << endl;  
  
s3 += "qrstuvwxyz";  
cout << s3.size() << endl << s3 << endl;
```

Standardklassen `std::string`

Operatörer på `string`

```
#include <string>  
  
s = t;                   // Tilldelning  
s.assign(t);            // Tilldelning  
s = s + " " + t;        // Konkaterering  
  
s<t, s==t               // Jämförelse  
s[k]                    // Indexering, hämta eller sätta värdet  
s.at(k)                 // Indexering med indexkontroll  
  
cout << s << t;         // Utskrift  
cin >> s;              // Inmatning av ord  
getline(cin, s);       // Inmatning av hel rad
```

Standardklassen `std::string`

Funktioner (metoder) i `string`

```
s.substr(k,n)  
s.erase(k,n)  
s.clear()  
s.size()  
s.append(t)  
s.insert(k,t)  
s.replace(k,m,t)  
s.find(t)
```

Sekvenser i C++

- ▶ En *sekvens* är en följd av element
- ▶ `std::vector`: variabel storlek, $O(1)$ indexering
- ▶ `std::array`: fast storlek, $O(1)$ indexering, lika effektiv som C-array, men säkrare
- ▶ `std::list`: variabel storlek, $O(1)$ insättning och borttagning, långsam ($O(n)$) indexering
- ▶ `std::deque`: variabel storlek, (effektivare än `vector`), $O(1)$ insättning och borttagning i början och slutet, $O(1)$ indexering.

Med *indexering* avses *random access*

Sekvenser: exempel

`std::vector`

Initiering

```
vector<int> a{1,2,3,4,5}; // som förväntat  
vector<int> b{5};        // {5}           ett element, 5  
vector<int> c(5);       // {0,0,0,0,0}   storlek=5
```

Initiering från C-array

```
int fib[] {1,1,2,3,5,8,13,21};  
vector<int> vfib(begin(fib), end(fib));  
  
for (int i : vfib) {cout << i << " ";}  
cout << endl;  
  
char str[] = "Hello World!"; // 13 tecken inklusive \0  
vector<char> v2(str, str+13); // "one past the end"
```

- ▶ iteratörer: mer om detta senare
- ▶ `begin()` och `end()` kan bara användas i det scope där `fib` deklarerats

Sekvenser: exempel

std::vector

```
void print_vector(vector<int>& v)
{
    for(auto x : v)
        cout << x << " ";
    cout << endl;
}
```

vector::push_back

```
vector<int> v; // tom vector

v.push_back(1);
v.push_back(2);
v.push_back(3);
print_vector(v);

v.clear();
v.push_back(5);
print_vector(v);

1 2 3
5
```

tilldelning

```
vector<int> v{1,3,5,7,9};
vector<int> v2(10);

print_vector(v);
print_vector(v2);

v2.at(4) = 7; // v2[4] (säker)
print_vector(v2);

v2 = v;
v = {1,2,3};
print_vector(v);
print_vector(v2);

1 3 5 7 9
0 0 0 0 0 0 0 0 0
0 0 0 0 7 0 0 0 0 0
1 2 3
1 3 5 7 9
```

Sekvenser: exempel

std::vector

Skyddsnet: vector::at() resp []

```
vector<int> a {0,1,2,3,4,5,6,7,8,9};

cout << "a[10]: " << a[10] << endl;

cout << "a.at(10): " << a.at(10) << endl;
```

```
a[10]: 33
terminate called after throwing an instance of 'std::out_of_range'
what(): vector::_M{range_check: __n (which is 10) >= this->size()
(which is 10) }
```

Sekvenser: exempel

std::array

Exempel

```
array<char,12> a1 {"Hello Again!"};

error: initializer-string for array of chars is too long
```

Exempel

```
array<char,13> a1 {"Hello Again!"};

for (char ch : a1) {
    cout << "[" << ch << "] ";
}
cout << endl;

[H][e][l][l][o][ ][A][g][a][i][n][!][ ]
```

NB! utan avslutande \0 blir längden 12:

```
std::array<char,12> a2{'H', 'e', 'l', 'l', 'o', ' ',
                    'A', 'g', 'a', 'i', 'n', '!'};
```

Vi har talat om

- ▶ Tecken
- ▶ C-strängar
- ▶ std::string
- ▶ Några standard-datatyper

Nästa föreläsning:

Vi kommer att gå igenom

- ▶ Funktioner
- ▶ Separatkompilering