Texthantering

- Introduktion
- Teckenkoder
- Indexering
- Skivor
- Jämförelser av strängar
- Loopa igenom en sträng
- Operatorerna *in*, + och *
- Inbyggda funktioner
- Inbyggda metoder
- Strängar är immutable

Introduktion

För texthantering behövs variabler som innehåller text. Dessa är av typen *str* (sträng/text). En sträng består av en sekvens av tecken.

```
s = '' # En tom sträng
s1 = 'python'   # eller "python" (enkelblippar el dubbelblippar)
print(s1)
print(type(s1))
```

→
```
python
<class 'str'>
```

Konkatenering av strängar med +

```
s2 = 'Programmering'
s3 = s2 + s1
print(s3)
```

→
```
Programmeringpython
```

```
s3 = s2 + 'i' + s1
print(s3)
```

→
```
Programmeringipython
```

```
s3 = s2 + ' i ' + s1
print(s3)
```

→
```
Programmering i python
```

Specialtecken i strängar:

`'\'` backslash
`'\n'` newline
`'\t'` tabulatortecken

Skriv fem tomma rader:
`print('\n'*5)`
(jmfr *-operatorn i Fö4)

```
s1 = 'Hej \n då'
print(s1)
```

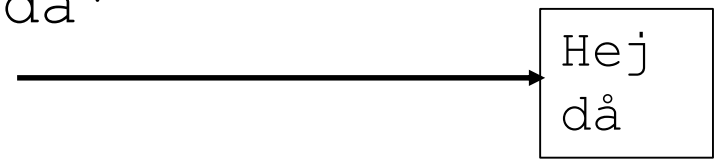


```
s1 = 'Hej \t då'
print(s1)
```

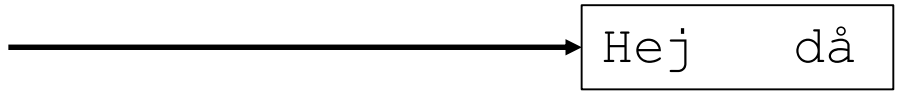


```
s1 = 'Hej \'då\' !'
print(s1)
```

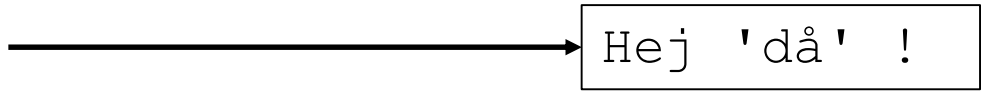


```
s2 = "Hej 'då' !"  # Använd dubbelfnuttar för avgränsning
print(s2)
```

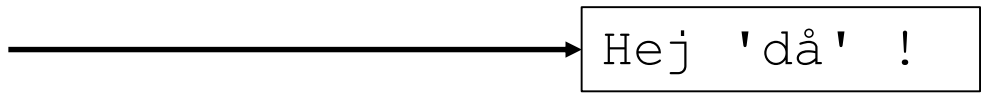

Teckenkoder

Tecken kodas som ett heltal, enligt *Unicode* (https://unicode-table.com/en/). Det finns plats för drygt 1 miljon tecken. En delmängd av den koden utgörs av *ASCII-koden.* Exvis har bokstaven (tecknet) A koden 65, B har koden 66, etc.

ASCII-koden omfattar 256 olika koder/tecken, vi kikar på www.asciitabell.se.
För 256 koder krävs ett binärt tal på 8 bitar. 256 = 11111111
Du ser t.ex. att tecknet A kodas som 65.
Tecknen i tabellen är ordnade så att versaler och gemener är samlade och de är sorterade i ordning. Dock problem med ordningen på de svenska Å, Ä och Ö.

Med funktionen ***ord*** kan vi ta reda på ascii-koden

```
s = 'A'           # En sträng med ett tecken
print(ord(s))     # Ger 65
```

Med funktionen ***chr*** kan vi konvertera från en kod till motsvarande teckenvärde.

```
s = chr(98) + chr(99)    # 98->b, 99->c
print(s)                 # ger bc
```

funktionen *chr* gör om en kod till ett tecken.
funktionen *str* gör om tal till en sträng.

```
s1 = '98' + '99' # konkatenera (slå ihop) de båda strängarna
s2 = 98 + 99     # addition av två heltal
s3 = chr(98) + chr(99) # slå ihop två tecken
s4 = str(9899)
print(s1)
print(s2)
print(s3)
print(s4)
```

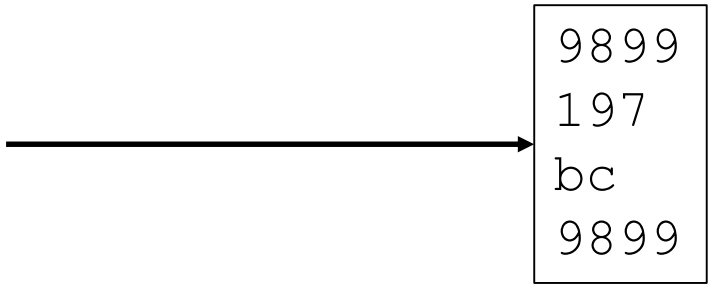

s1, s3, s4 är av typen str
s2 är av typen int

```
s5 = 'a7 G!'
```

Strängen `s5` är en sekvens av tecken,
kan illustreras enligt:

Men varje tecken är
lagrat (kodat) som:

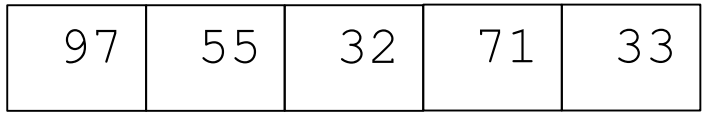

Men detta kodas egentligen binärt…

Göra om tecken, “kryptera”

Utgående från ascii-koden ges möjlighet att göra om tecken
Ett exempel, gör om tecknet A till B:

```
t = 'A'
```

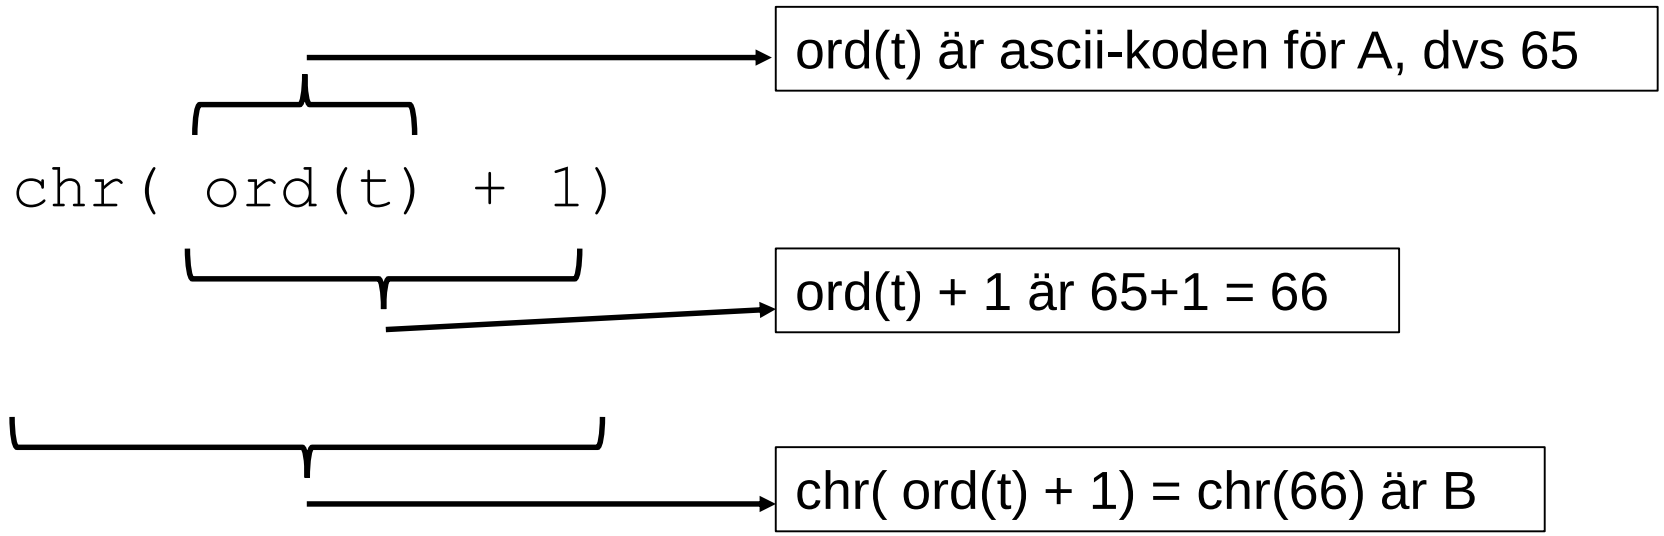


```
print(t) # Ger B
```

Skapa ett slumptecken

```
slump = chr(ord('A') + random.randint(0,25))
```

Ger ett slumptecken, en bokstav: `'A' – 'Z'`

Förklaring till ovan sats:
'A' har koden 65. Om man till detta värde adderar ett slumptal som kan vara 0-25 blir resultatet 65-90. Detta motsvarar koderna för 'A' **-** 'Z'**.**

Om vi gör om dessa koder 65-90 till teckenvärden med (char) kommer det istället att bli ett teckenvärde 'A'**-**'Z'**,** som lagras i variabeln slump**.**

Nu kan vi ana hur man kan skapa slumpade lösenord

Nu kan vi "kryptera" text:
Vi kikar på filen encrypt.py

Vad händer om texten innehåller blanktecken?

I koden *Unicode* ges möjlighet att koda mer än 1 miljon olika tecken (32-bit). Se *Unicode*: www.unicode.coeurlumiere.com. F.n. är cirka 140 000 definierade.

(De 256 första tecknen i Unicode är ASCII-tecknen.)

Unicode uttrycks lämpligen hexadecimal. Tecknet A är kodat till 65, dvs 41 uttryckt hexadecimalt. $41 = 4*16^1 + 1*16^0$

```
ch1 = '\u0041'     # 41 hexadecimalt = 65 (A)
ch2 = '\u2663'
ch3 = '\u03A8'
ch4 = '\u263A'
print(ch1, ch2, ch3, ch4)
```

`\u` ovan står för Unicode

Indexering och strängar

```
s = 'python'
```

`s` är sex tecken lång, dvs består av sex element

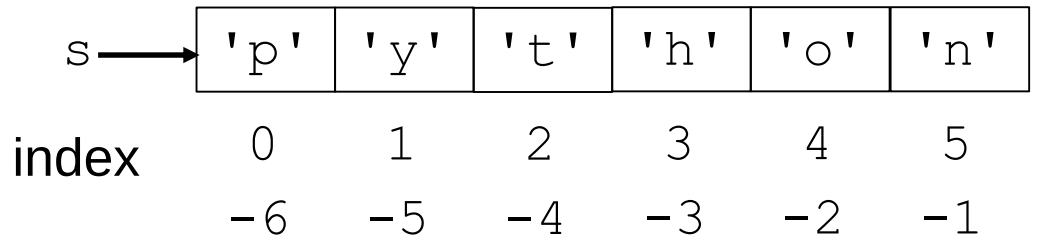

Indexering relativt första elementet

Indexering relativt sista elementet

```
print(s[0], s[-3])
s2 = s[-1] + s[2]
print(s2)
```

```
p h
nt
```

Längden av en sträng

```
s = 'python'

print(len(s))
```

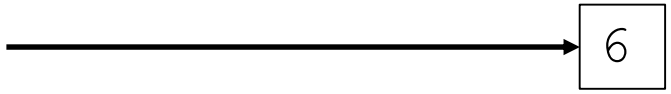

Skriv ut sista elementet

```
print(s[len(s)])
```

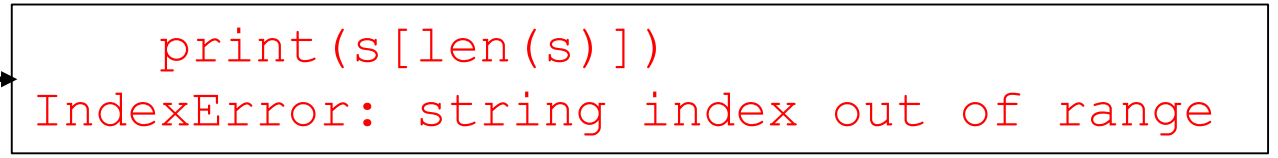

Två alternativ

```
print(s[len(s)-1])
print(s[-1])
```

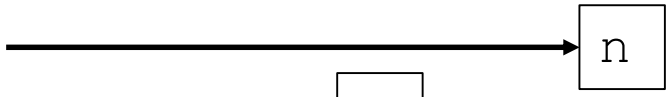

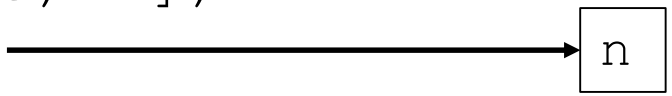

Skivor av en sträng

När man indexerar väljer man ut ett enda element. Med *skivning* kan man välja flera element.

```
s = 'python'
   # 012345 (index)
s2 = s[3:6]     # s2 blir 'hon'
s2 = s[:4]      # s2 blir 'pyth'
s2 = s[4:]      # s2 blir 'on'
s2 = s[4:1:-1] # s2 blir 'oht'
s2 = s[::-1]    # s2 blir 'nohtyp'
```

Allmänt gällande skivning `s[först:sist:steg]`

```
s = 'naturrutan'
if s == s[::-1]:
    print(s + ' är ett palindrom') → naturrutan är ett palindrom
```

Jämförelser av strängar

```
s1 = 'abc'
s2 = 'abcd'
s3 = 'abC'

print(s1=='abc')  # ger True
print(s1<s2)      # ger True
print(s1<s3)      # ger False
print('a' < 'Ab') # ger False
```

Jämförelse baseras på ascii-koden, från vänster till höger
Om tecknen är lika i de båda strängarna, är en kortare sträng “mindre”

Loop genom en sträng med operatorn *in*, ex räkna antal x i en text:

```
s = input('Skriv en text') # sex laxar in en laxask
n = 0
# för varje element c i s
for c in s:     # c = s,e,x,…
    if c == 'x':
        n = n + 1
print('Antal tecken x:', n) # Antal tecken x: 3
```

Alt 2 (sämre)

```
# för varje index i s
for i in range(0, len(s)): # i = 0..21
    if s[i]== 'x':
        n = n + 1
print('Antal tecken x:', n) # Antal tecken x: 3
```

Alt 3:

```
n = 0
# för varje index (i) och element (c)
for i,c in enumerate(s):
    if c == 'x':
        n = n + 1
print('Antal tecken x:', n) # Antal tecken x: 3
```

Alt 4, enklast med pythons inbyggda metod `count`:

```
print(s.count('x'))   # 3
```

Operatorerna *in*, + och *

Förutom att användas i loop kan operatorn *in* användas för att undersöka om ett element finns i en sträng:

```
s = 'sex laxar i en laxask'
if 'x' in s:
    print('x finns i', s) -> x finns i sex laxar in en laxask
```

Operatorn + för att bygga en ny sträng:

```
s1 = 'nej'
s1 = s1 + '!'  # -> 'nej!'     (en ny sträng s1 skapas)
```

Kan ej ändra elementen i en sträng:

```
s1[1] = 'Q'    #
```

```
s1[1] = 'Q'
TypeError: 'str' object does not
support item assignment
```

Operatorn * för att bygga en ny sträng:

```
s2 = 3 * s1  # el s1 * 3
print(s2)  # -> 'nej!nej!nej!'
```

Exempel på inbyggd funktion lämplig för strängar:

```
s = 'python'
print(len(s)) # ger 6
```

Finns andra inbyggda funktioner (ex min,max), men ej så användbara på strängar

Några exempel på metoder för strängar (metoder anropas med punktnotation)

```
s = 'python'
print(s.find('y'))  # ger 1, metoden ger ett index
print(s.upper())    # 'PYTHON'

print(s.isalpha())  # ger True, alla tecken är bokstäver
print(s.isdecimal())# ger False, alla tecken är ej siffror

ramsa = 'Sex laxar i en laxask'
print(ramsa.replace('lax','mört'))

# ger: Sex mörtar i en mörtask
```

fortsättning →

Några exempel på metoder för strängar (metoder anropas med punktnotation)

```
ramsa = 'Sex laxar i en laxask'
lst = ramsa.split() # Splittar map på blanktecken
# ger ['Sex', 'laxar', 'i', 'en', 'laxask’]
n = ramsa.count('ax')  # Ger 2

s = '  abc '
s2 = s.strip())      # ger  'abc' tar omgivande blanka
s3 = s2.upper()      # ger  'ABC'
s4 = s3.lower()      # ger  'abc'
m =  s4.index('b')   # ger 1, dvs 2:a tecknet, börjar på 0

s = '8abcKL'
print(s.isalpha())  # Ger False, kollar om bara bokstäver
print(s[2:].isalpha()) # Ger True
```

Alla metoder, se https://www.w3schools.com/python/python_ref_string.asp

Operatorer på strängar:

`in, +, *, >, <, ==` (+ och * känner vi till sedan tidigare)

```
if s1 in s2:  # Om strängen s1 finns i strängen s2
    …

if (s1 == s2): # Om strängarna är exakt lika
    …

if (s1 < s2):  # 'bus' < 'busa' ger True
    …          # 'buss' < 'busar' ger False
```

Python jämför tecken för tecken tills strängarna är slut eller det skiljer

Typomvandling av strängar

`int(s)` och **`float(s)`** fungerar om `s` är sträng som går att omvandla.

Strängar är *immutable*, dvs det går ej att ändra dess element, till skillnad mot exvis listor.

```
s ='abcd'
s[1] = 'X'    # Vill byta ut c mot X
TypeError: 'str' object does not support item assignment
```

Kan ej ändra element i en sträng

```
s ='abcd'
s[2:3] = 'X' # Önskar byta c mot X mha skivning
TypeError: 'str' object does not support item assignment
```

Kan komma runt det med exvis:

```
s = s[:2] + 'X' + s[3:]
```

Men `s` referar nu till en annan sträng

Alla sträng-metoder returnerar nya värden, de ändrar ej original-strängen.