

DD1361

Programmeringsparadigm

Formella Språk & Syntaxanalys  
Föreläsning 1

Per Austrin

2015-11-10

# Kursavsnittet syntax/formella språk

- **Teori om formella språk –  
verktygslåda för strängmatchning:**
  - Ändliga automater och reguljära uttryck
  - Olika kraftfulla språkklasser
- **Formella språk i praktiken:**
  - Regex
  - Lexikal analys
  - Att skriva en parser för ett språk

Idag

Reguljära uttryck

Ändliga automater

Formella språk

Några praktiska exempel

Idag

Reguljära uttryck

Ändliga automater

Formella språk

Några praktiska exempel

# Reguljära uttryck

Reguljära uttryck är *mönster* för att beskriva hur en sträng ska se ut.

Man kan säga att det är ett språk för att beskriva strängar.

# Reguljära uttryck

Reguljära uttryck är *mönster* för att beskriva hur en sträng ska se ut.

Man kan säga att det är ett språk för att beskriva strängar.

## **Exempel:**

Vi är intresserade av namnen på de obligatoriska labbarna i kursen:

F1, F2, L1, L2, S1, S2, Inet

# Reguljära uttryck

Reguljära uttryck är *mönster* för att beskriva hur en sträng ska se ut.

Man kan säga att det är ett språk för att beskriva strängar.

## **Exempel:**

Vi är intresserade av namnen på de obligatoriska labbarna i kursen:

F1, F2, L1, L2, S1, S2, Inet

Vi kan beskriva dem med det reguljära uttrycket

F1|F2|L1|L2|S1|S2|Inet

# Reguljära uttryck

Reguljära uttryck är *mönster* för att beskriva hur en sträng ska se ut.

Man kan säga att det är ett språk för att beskriva strängar.

## Exempel:

Vi är intresserade av namnen på de obligatoriska labbarna i kursen:

F1, F2, L1, L2, S1, S2, Inet

Vi kan beskriva dem med det reguljära uttrycket

F1 | F2 | L1 | L2 | S1 | S2 | Inet

Vertikalstreck/pipetecken är en operator i reguljära uttryck som betyder “eller” – antingen vänstra eller högra operanden

## Fortsättning på exempel

Namnen på labbarna i kursen följer ju egentligen ett tämligen enkelt mönster:

- Antingen är strängen "Inet"
- Eller så består den av något av tecknen 'F', 'L' eller 'S', följt av något av tecknen '1' eller '2'

## Fortsättning på exempel

Namnen på labbarna i kursen följer ju egentligen ett tämligen enkelt mönster:

- Antingen är strängen "Inet"
- Eller så består den av något av tecknen 'F', 'L' eller 'S', följt av något av tecknen '1' eller '2'

Denna typ av beskrivning kan formuleras i reguljära uttryck:

`Inet|(F|L|S)(1|2)`

## Fortsättning på exempel

Namnen på labbarna i kursen följer ju egentligen ett tämligen enkelt mönster:

- Antingen är strängen "Inet"
- Eller så består den av något av tecknen 'F', 'L' eller 'S', följt av något av tecknen '1' eller '2'

Denna typ av beskrivning kan formuleras i reguljära uttryck:  
Inet | (F | L | S) (1 | 2)

Parenteser används för att gruppera uttryck

## Fortsättning på exempel

Namnen på labbarna i kursen följer ju egentligen ett tämligen enkelt mönster:

- Antingen är strängen "Inet"
- Eller så består den av något av tecknen 'F', 'L' eller 'S', följt av något av tecknen '1' eller '2'

Denna typ av beskrivning kan formuleras i reguljära uttryck:  
Inet | (F | L | S) (1 | 2)

Parenteser används för att gruppera uttryck

Antingen F eller L eller S

## Fortsättning på exempel

Namnen på labbarna i kursen följer ju egentligen ett tämligen enkelt mönster:

- Antingen är strängen "Inet"
- Eller så består den av något av tecknen 'F', 'L' eller 'S', följt av något av tecknen '1' eller '2'

Denna typ av beskrivning kan formuleras i reguljära uttryck:

Inet | (F | L | S) (1 | 2)

Parenteser används för att gruppera uttryck

Antingen F eller L eller S

Antingen 1 eller 2

# Fortsättning på exempel

Namnen på labbarna i kursen följer ju egentligen ett tämligen enkelt mönster:

- Antingen är strängen "Inet"
- Eller så består den av något av tecknen 'F', 'L' eller 'S', följt av något av tecknen '1' eller '2'

Denna typ av beskrivning kan formuleras i reguljära uttryck:  
Inet | (F|L|S) (1|2)

Parenteser används för att gruppera uttryck

Antingen F eller L eller S

Antingen 1 eller 2

(Antingen F eller L eller S) följt av (antingen 1 eller 2)

## Exempel 2 – upprepning

### **Exempel:**

Vi är intresserade av alla binära strängar:

“”, “0”, “1”, “00”, “01”, “10”, “11”, ...

## Exempel 2 – upprepning

### **Exempel:**

Vi är intresserade av alla binära strängar:

“”, “0”, “1”, “00”, “01”, “10”, “11”, ...

Oändligt många strängar, vi kan inte skriva en lista med alla

## Exempel 2 – upprepning

### Exempel:

Vi är intresserade av alla binära strängar:

“”, “0”, “1”, “00”, “01”, “10”, “11”, ...

Oändligt många strängar, vi kan inte skriva en lista med alla

Vi kan beskriva dem med det reguljära uttrycket

$(0|1)^*$

## Exempel 2 – upprepning

### Exempel:

Vi är intresserade av alla binära strängar:

“”, “0”, “1”, “00”, “01”, “10”, “11”, ...

Oändligt många strängar, vi kan inte skriva en lista med alla

Vi kan beskriva dem med det reguljära uttrycket

$(0|1)^*$

Uppprepningsoperatorn ‘\*’ betyder:

“det som stod precis framför, ett valfritt antal gånger”

## Exempel 2 – upprepning

### Exempel:

Vi är intresserade av alla binära strängar:

“”, “0”, “1”, “00”, “01”, “10”, “11”, ...

Oändligt många strängar, vi kan inte skriva en lista med alla

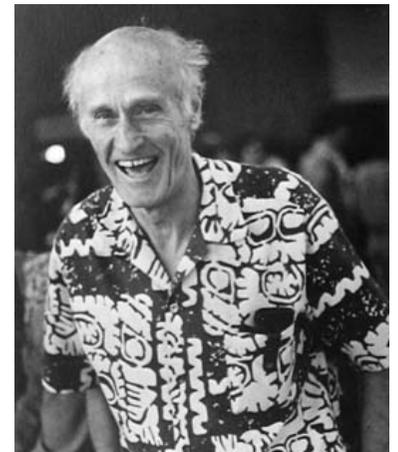
Vi kan beskriva dem med det reguljära uttrycket

$(0|1)^*$

Uppprepningsoperatorn ‘\*’ betyder:

“det som stod precis framför, ett valfritt antal gånger”

Den här operationen kallas även Kleene-stjärna eller Kleene-slutning (Kleene closure)



# Reguljära uttryck – sammanfattning av operationerna

**Konkatenering:** “`abc`” beskriver `a` följt av `b` följt av `c` (dvs strängen `abc`).

# Reguljära uttryck – sammanfattning av operationerna

**Konkatenering:** “ $abc$ ” beskriver  $a$  följt av  $b$  följt av  $c$  (dvs strängen  $abc$ ).

**Alternering:** “ $ab|cd$ ” beskriver någon av strängarna  $ab$  eller  $cd$ .

# Reguljära uttryck – sammanfattning av operationerna

**Konkatenering:** “ $abc$ ” beskriver  $a$  följt av  $b$  följt av  $c$  (dvs strängen  $abc$ ).

**Alternering:** “ $ab|cd$ ” beskriver någon av strängarna  $ab$  eller  $cd$ .

**Gruppering:** Kan använda parenteser för att ändra i vilken ordning konkatenering och alternering görs: “ $a(b|c)d$ ” beskriver någon av strängarna  $abd$  eller  $acd$

# Reguljära uttryck – sammanfattning av operationerna

**Konkatenering:** “ $abc$ ” beskriver  $a$  följt av  $b$  följt av  $c$  (dvs strängen  $abc$ ).

**Alternering:** “ $ab|cd$ ” beskriver någon av strängarna  $ab$  eller  $cd$ .

**Gruppering:** Kan använda parenteser för att ändra i vilken ordning konkatenering och alternering görs: “ $a(b|c)d$ ” beskriver någon av strängarna  $abd$  eller  $acd$

**Upprepning:** “ $a(b|c)*d$ ” beskriver alla strängar som börjar på  $a$ , slutar på  $d$ , och däremellan har vilken sträng som helst bestående av tecknen  $b$  och  $c$ , t.ex.  $acccccccd$ ,  $acbd$ ,  $abbbcccbcbcd$  och  $ad$ .

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

De vanligaste och mest oumbärliga exemplen:

- **Teckenmängd:** “[abcd]” betyder “a|b|c|d” något av tecknena a, b c eller d

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

De vanligaste och mest oumbärliga exemplen:

- **Teckenmängd:** “[abcd]” betyder “a|b|c|d” något av tecknena a, b c eller d
- **Teckenintervall:** “[a-d]” betyder samma som ovan – något av tecknen i intervallet

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

De vanligaste och mest oumbärliga exemplen:

- **Teckenmängd:** “[abcd]” betyder “a|b|c|d” något av tecknena a, b c eller d
- **Teckenintervall:** “[a-d]” betyder samma som ovan – något av tecknen i intervallet
- **Teckenkomplement:** “[^a-d]” beskriver alla tecken som *inte* är i intervallet

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

De vanligaste och mest oumbärliga exemplen:

- **Teckenmängd:** “[abcd]” betyder “a|b|c|d” något av tecknena a, b c eller d
- **Teckenintervall:** “[a-d]” betyder samma som ovan – något av tecknen i intervallet
- **Teckenkomplement:** “[^a-d]” beskriver alla tecken som *inte* är i intervallet
- **Noll eller en:** “X?” betyder “(|X)”, dvs antingen en tom sträng eller X

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

De vanligaste och mest oumbärliga exemplen:

- **Teckenmängd:** “[abcd]” betyder “a|b|c|d” något av tecknena a, b c eller d
- **Teckenintervall:** “[a-d]” betyder samma som ovan – något av tecknen i intervallet
- **Teckenkomplement:** “[^a-d]” beskriver alla tecken som *inte* är i intervallet
- **Noll eller en:** “X?” betyder “(|X)”, dvs antingen en tom sträng eller X
- **En eller flera:** “X+” betyder “XX\*”, dvs en eller flera upprepningar av X

# Syntaktiskt socker

I praktiken lägger man alltid till lite syntaktiskt socker till reguljära uttryck för att förenkla en del konstruktioner.

De vanligaste och mest outhärliga exemplen:

- **Teckenmängd:** “[abcd]” betyder “a|b|c|d” något av tecknena a, b c eller d
- **Teckenintervall:** “[a-d]” betyder samma som ovan – något av tecknen i intervallet
- **Teckenkomplement:** “[<sup>^</sup>a-d]” beskriver alla tecken som *inte* är i intervallet
- **Noll eller en:** “X?” betyder “(|X)”, dvs antingen en tom sträng eller X
- **En eller flera:** “X+” betyder “XX\*”, dvs en eller flera upprepningar av X
- **Godtyckligt tecken:** “.” betyder “vilket tecken som helst”

## Exempel: e-post-adresser

**Exempel:** skriv ett reguljärt uttryck som beskriver giltiga e-post-adress.

## Exempel: e-post-adresser

**Exempel:** skriv ett reguljärt uttryck som beskriver giltiga e-post-adresser.

I det här exemplet definierar vi giltig e-post-adress enligt följande regler:

1. Adressen består av en lokal del och ett domännamn, som separeras av @.
2. Den lokala delen får bestå av
  - stora, små bokstäver och siffror,
  - punkter, men inte som första eller sista tecken i lokala delen.
3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av
  - stora, små bokstäver och siffror,
  - punkter, men inte som första eller sista tecken i lokala delen.

# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av

- stora, små bokstäver och siffror,
- punkter, men inte som första eller sista tecken i lokala delen.

Reguljära uttryck för de tillåtna tecknen:

`[A-Za-z0-9.]` – inklusive punkt

`[A-Za-z0-9]` – exklusive punkt

# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av

- stora, små bokstäver och siffror,
- punkter, men inte som första eller sista tecken i lokala delen.

Reguljära uttryck för de tillåtna tecknen:

$[A-Za-z0-9.]$  – inklusive punkt

$[A-Za-z0-9]$  – exklusive punkt

Reguljärt uttryck för lokal del:

$[A-Za-z0-9][A-Za-z0-9.]*[A-Za-z0-9]$

# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av

- stora, små bokstäver och siffror,
- punkter, men inte som första eller sista tecken i lokala delen.

Reguljära uttryck för de tillåtna tecknen:

`[A-Za-z0-9.]` – inklusive punkt

`[A-Za-z0-9]` – exklusive punkt

Reguljärt uttryck för lokal del:

`[A-Za-z0-9][A-Za-z0-9.]*[A-Za-z0-9]`

Första tecknet  
ej punkt

Sista tecken ej  
punkt

Tecken däremellan får  
även vara punkt

# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av

- stora, små bokstäver och siffror,
- punkter, men inte som första eller sista tecken i lokala delen.

Reguljära uttryck för de tillåtna tecknen:

$[A-Za-z0-9.]$  – inklusive punkt

$[A-Za-z0-9]$  – exklusive punkt

Reguljärt uttryck för lokal del:

$[A-Za-z0-9][A-Za-z0-9.]*[A-Za-z0-9]$

**Eller...?**

# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av

- stora, små bokstäver och siffror,
- punkter, men inte som första eller sista tecken i lokala delen.

Reguljära uttryck för de tillåtna tecknen:

[A-Za-z0-9.] – inklusive punkt

[A-Za-z0-9] – exklusive punkt

Reguljärt uttryck för lokal del:

[A-Za-z0-9][A-Za-z0-9.]\*[A-Za-z0-9]

## Eller...?

Uttrycket antar att lokala delen består av minst två tecken – men det ska vara tillåtet för den lokala delen att bestå av ett enda tecken – fel!



# Reguljärt uttryck för lokal del

2. Den lokala delen får bestå av

- stora, små bokstäver och siffror,
- punkter, men inte som första eller sista tecken i lokala delen.

Reguljära uttryck för de tillåtna tecknen:

`[A-Za-z0-9.]` – inklusive punkt

`[A-Za-z0-9]` – exklusive punkt

Reguljärt uttryck för lokal del – försök 2:

`[A-Za-z0-9] ([A-Za-z0-9.] * [A-Za-z0-9]) ?`

## Reguljärt uttryck för domännamn

3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

## Reguljärt uttryck för domännamn

3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

Reguljärt uttryck för “icke-tom sträng med bara små bokstäver och siffror” :

`[a-z0-9]+`

# Reguljärt uttryck för domännamn

3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

Reguljärt uttryck för “icke-tom sträng med bara små bokstäver och siffror”:

$[a-z0-9]^+$

Reguljärt uttryck för domändelen:

$[a-z0-9]^+(\.[a-z0-9]^+)^*$

# Reguljärt uttryck för domännamn

3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

Reguljärt uttryck för “icke-tom sträng med bara små bokstäver och siffror”:

`[a-z0-9]+`

Reguljärt uttryck för domändelen:

`[a-z0-9]+(\.[a-z0-9]+)*`

Icke-tom sträng med  
små bokstäver och  
siffror

Punkt följd av icke-tom  
sträng med små  
bokstäver och siffror

Upprepat 0 eller fler gånger

# Reguljärt uttryck för domännamn

3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

Reguljärt uttryck för “icke-tom sträng med bara små bokstäver och siffror”:

`[a-z0-9]+`

Reguljärt uttryck för domändelen:

`[a-z0-9]+(\.[a-z0-9]+)*`

Fel igen! Tillåter domändel med bara en del, ska vara minst två!

# Reguljärt uttryck för domännamn

3. Domännamnet är en lista med minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror.

Reguljärt uttryck för “icke-tom sträng med bara små bokstäver och siffror”:

$[a-z0-9]^+$

Reguljärt uttryck för domändelen:

$[a-z0-9]^+(\.[a-z0-9]^+)^+$

# Sätta ihop lösningen

1. Adressen består av en lokal del och ett domännamn, som separeras av @.

# Sätta ihop lösningen

1. Adressen består av en lokal del och ett domännamn, som separeras av @.

Reguljärt uttryck för lokal del:

$[A-Za-z0-9]([A-Za-z0-9.]^*[A-Za-z0-9])?$

Reguljärt uttryck för domändelen:

$[a-z0-9](\.[a-z0-9])^+$

# Sätta ihop lösningen

1. Adressen består av en lokal del och ett domännamn, som separeras av @.

Reguljärt uttryck för lokal del:

$[A-Za-z0-9]([A-Za-z0-9.]^*[A-Za-z0-9])?$

Reguljärt uttryck för domändelen:

$[a-z0-9]+(\.[a-z0-9]+)^+$

Kombinerat till ett reguljärt uttryck för e-post-adresser:

$[A-Za-z0-9]([A-Za-z0-9.]^*[A-Za-z0-9])?@[a-z0-9]+(\.[a-z0-9]+)^+$

# Sätta ihop lösningen

1. Adressen består av en lokal del och ett domännamn, som separeras av @.

Reguljärt uttryck för lokal del:

$[A-Za-z0-9] ([A-Za-z0-9.]^* [A-Za-z0-9])?$

Reguljärt uttryck för domändelen:

$[a-z0-9]+(\.[a-z0-9]+)^+$

Kombinerat till ett reguljärt uttryck för e-post-adresser:

$[A-Za-z0-9] ([A-Za-z0-9.]^* [A-Za-z0-9])?@[a-z0-9]+(\.[a-z0-9]+)^+$

(De riktiga reglerna för hur en giltig e-post-adress ser ut är mycket mer komplicerade, det här var bara ett litet leksaks-exempel)



Idag

Reguljära uttryck

Ändliga automater

Formella språk

Några praktiska exempel

# Ändliga automater

Ändliga automater är, precis som reguljära uttryck, ett verktyg för att beskriva en uppsättning strängar

Den enklaste typen av automat kallas för *DFA, Deterministic Finite Automaton*.

Lite informellt är en DFA en “maskin” som kan befinna sig i en given uppsättning olika tillstånd, som läser en sträng tecken för tecken och byter tillstånd baserat på de tecken som läses, enligt en given uppslagstabell.

# Progp-labbarna igen

De obligatoriska progp-labbarna:

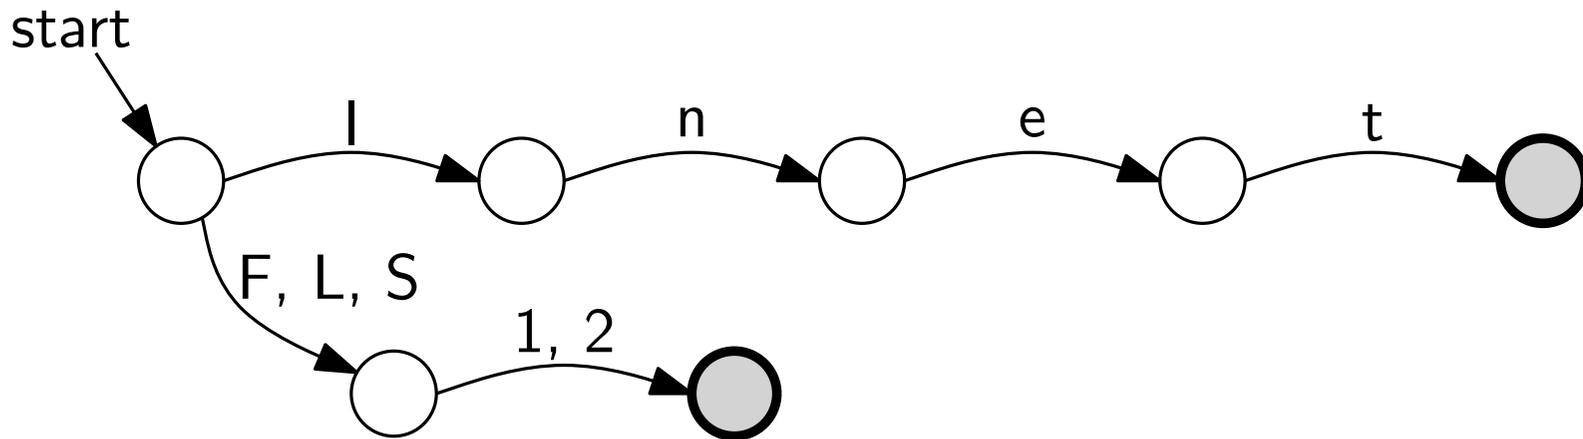
F1, F2, L1, L2, S1, S2, Inet

# Progplabbarna igen

De obligatoriska progplabbarna:

F1, F2, L1, L2, S1, S2, Inet

Dessa kan beskrivas med följande ändliga automat

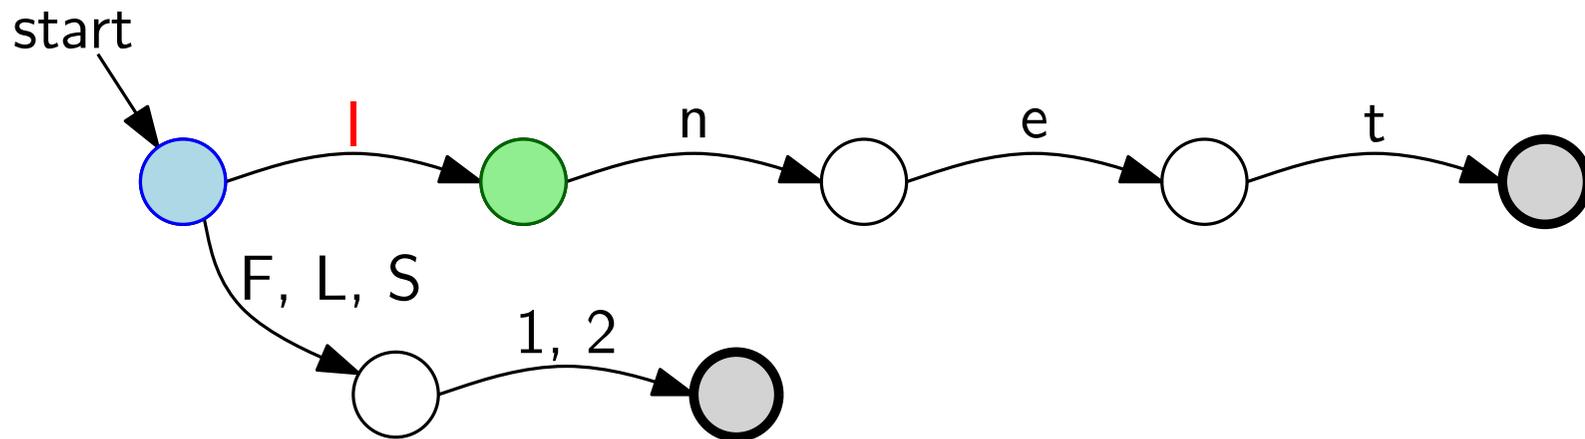


# Progplabbarna igen

De obligatoriska progplabbarna:

F1, F2, L1, L2, S1, S2, Inet

Dessa kan beskrivas med följande ändliga automat



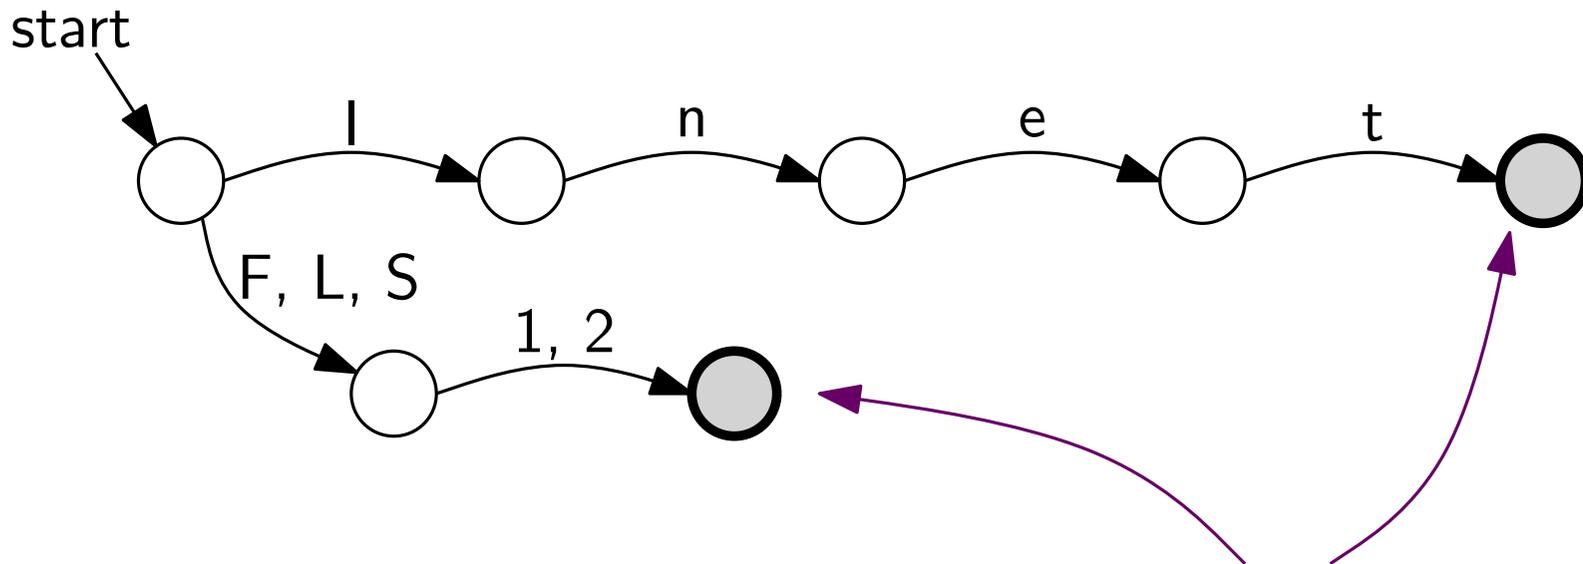
Om vi **befinner oss här** och **nästa tecken är ett 'l'**, hoppa hit

# Prog-labbarna igen

De obligatoriska prog-labbarna:

F1, F2, L1, L2, S1, S2, Inet

Dessa kan beskrivas med följande ändliga automat



Om vi befinner oss i något av dessa tillstånd när strängen är slut så är det en korrekt sträng

# Lite mer formellt

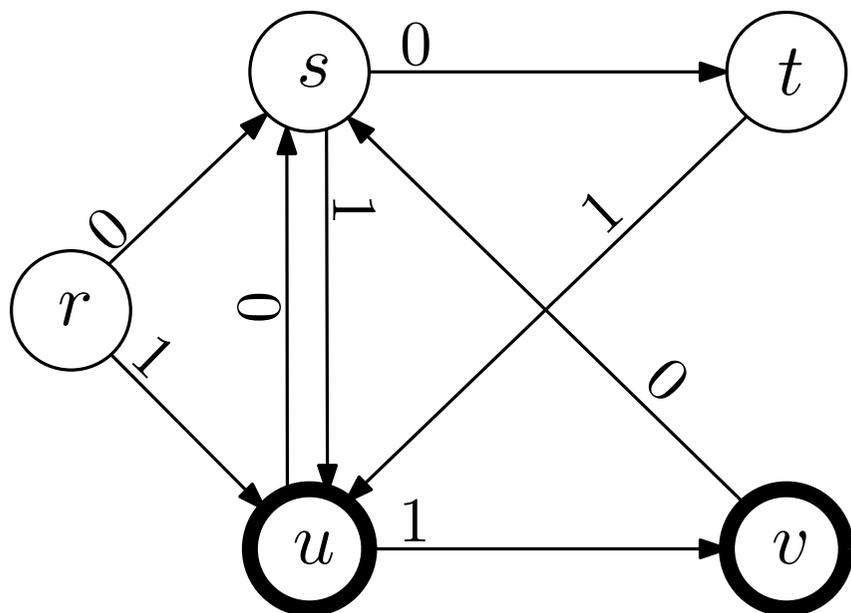
En ändlig automat består av:

- ett antal *tillstånd*
- *övergångar* mellan tillstånden, märkta med något tecken
- ett tillstånd är *starttillstånd*
- något/några tillstånd är *accepterande tillstånd*

## Lite mer formellt

En ändlig automat består av:

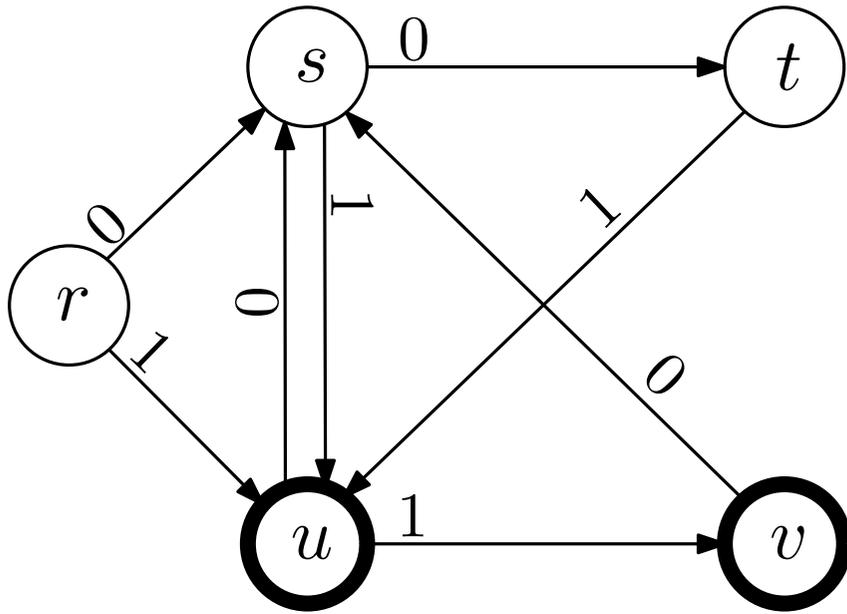
- ett antal *tillstånd*
- *övergångar* mellan tillstånden, märkta med något tecken
- ett tillstånd är *starttillstånd*
- något/några tillstånd är *accepterande tillstånd*



Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

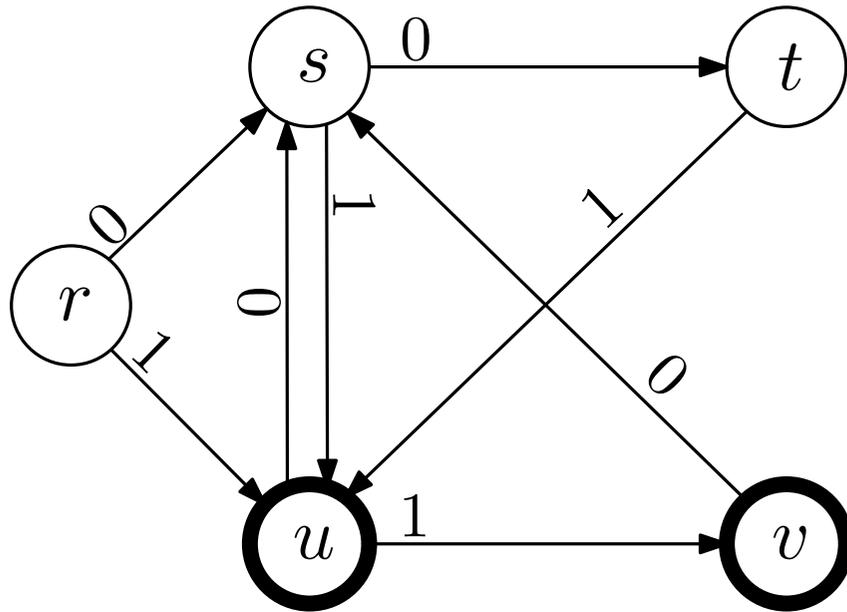
# Exempel 1



Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

# Exempel 1

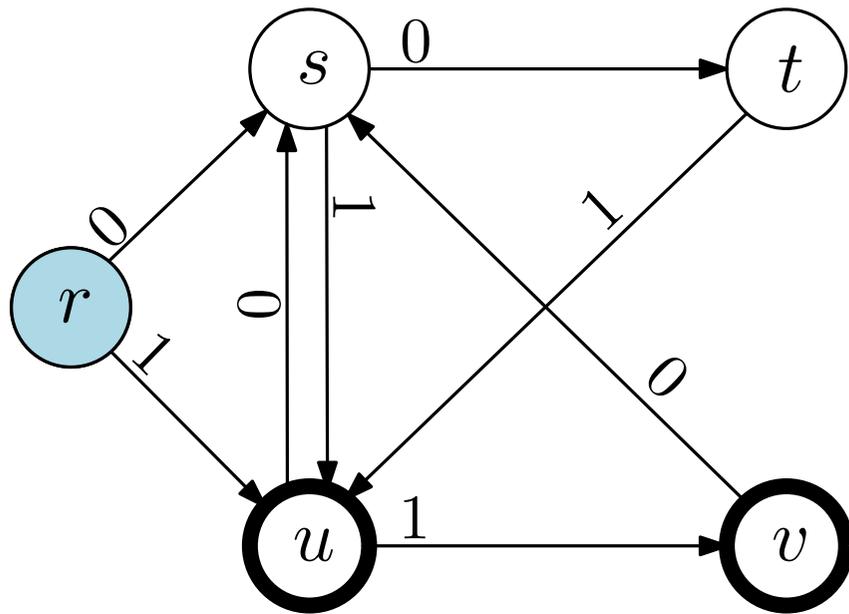


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

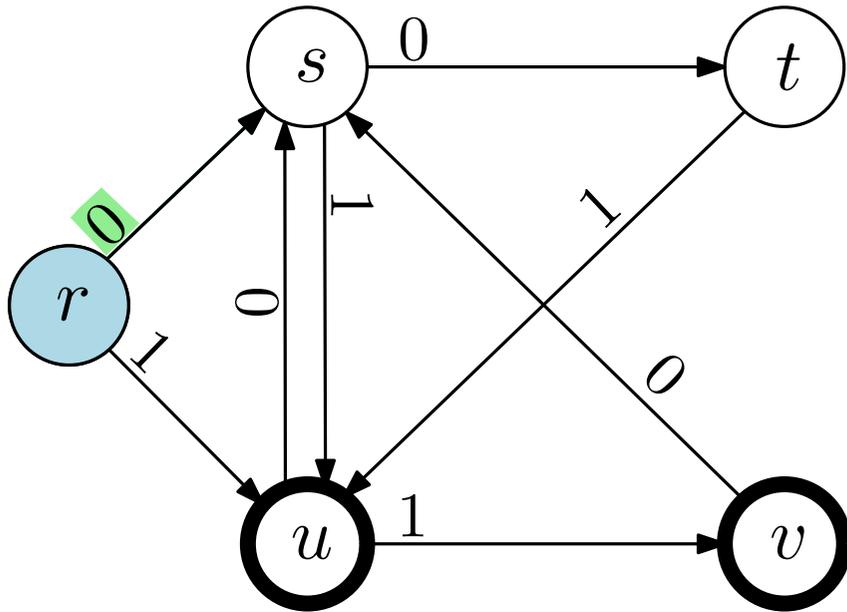


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

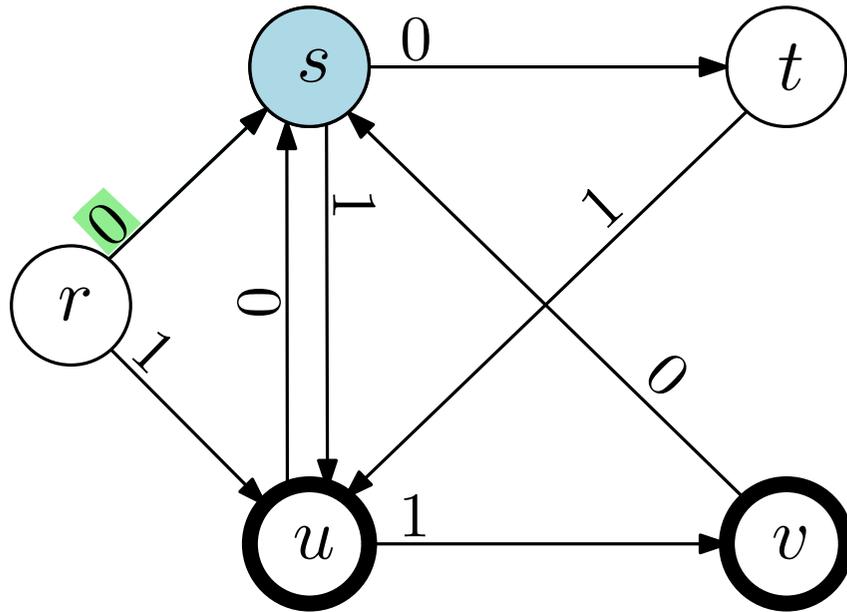


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

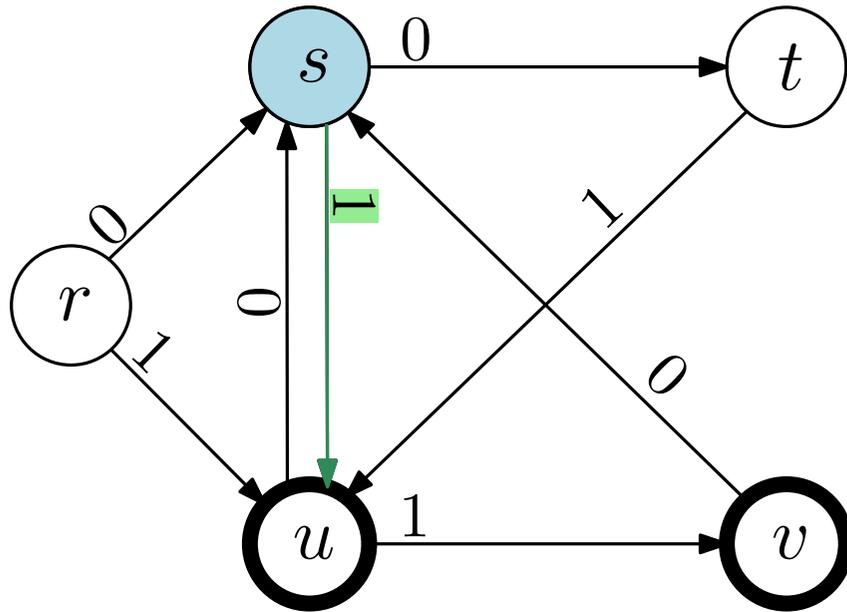


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

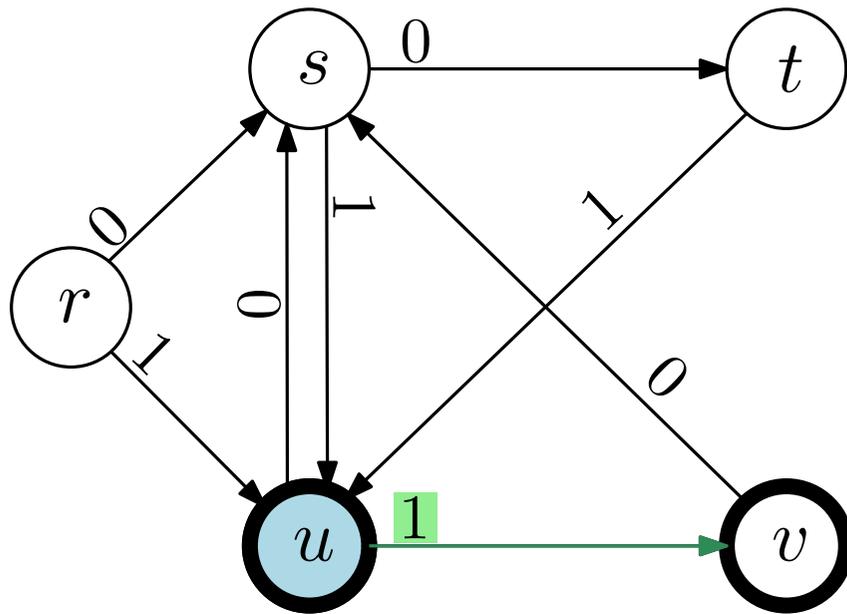


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

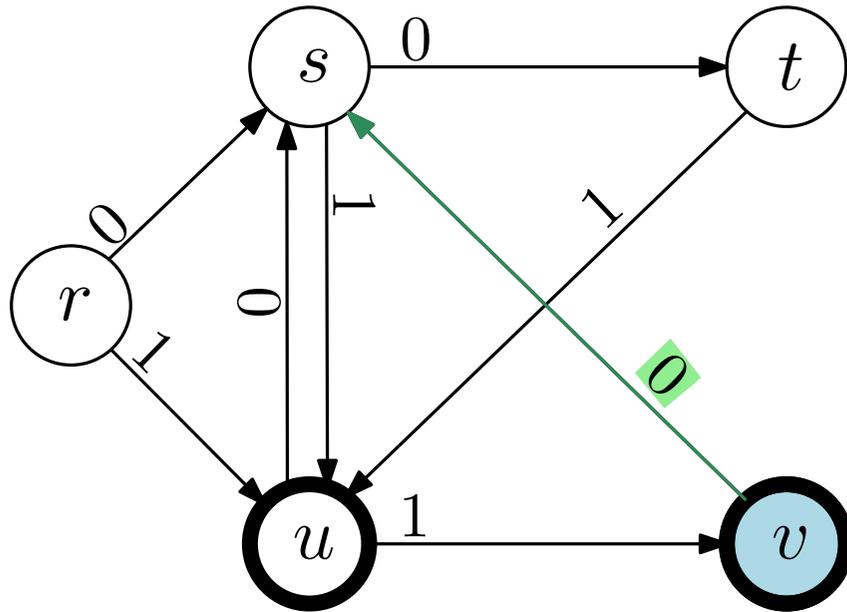


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

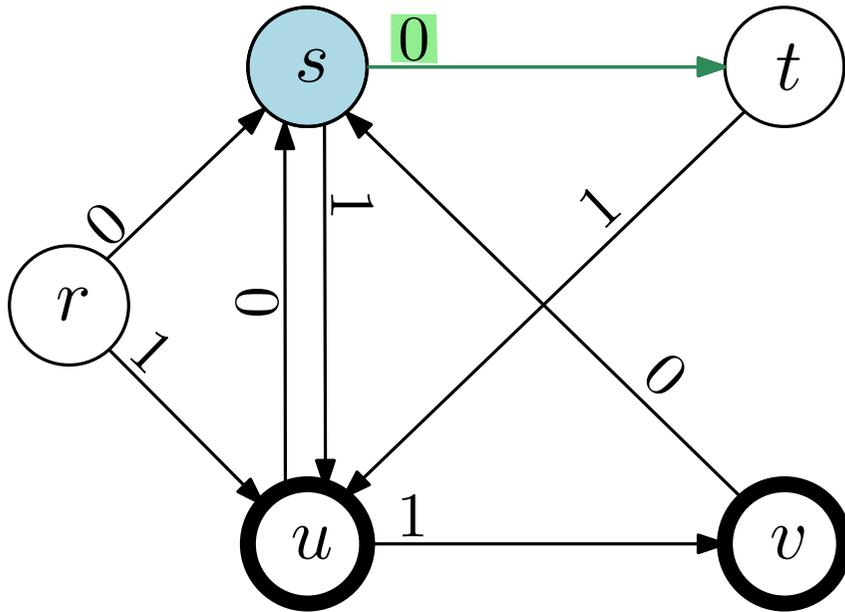


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

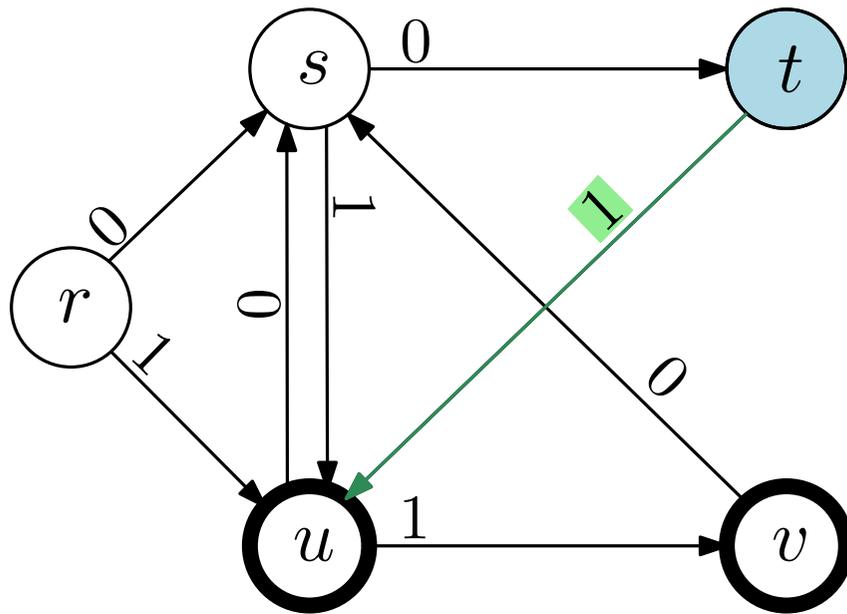


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

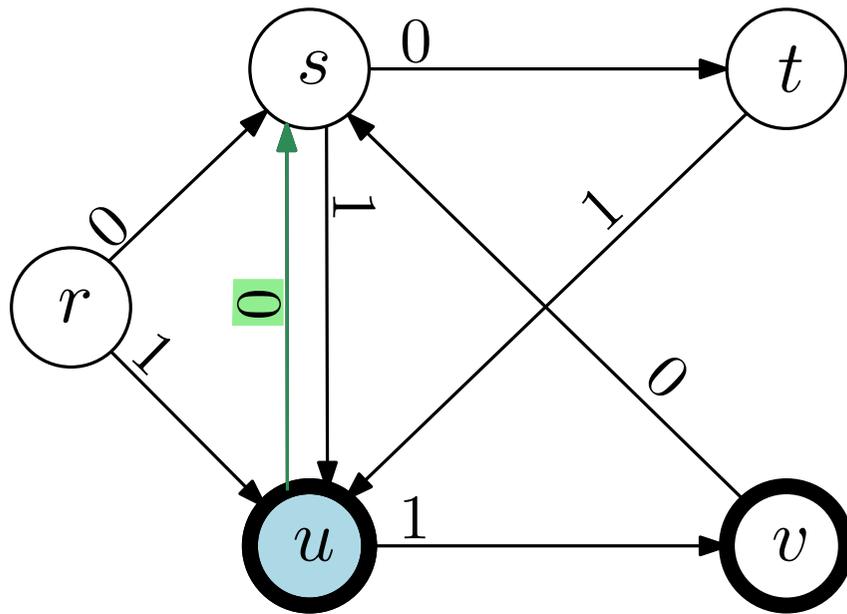


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

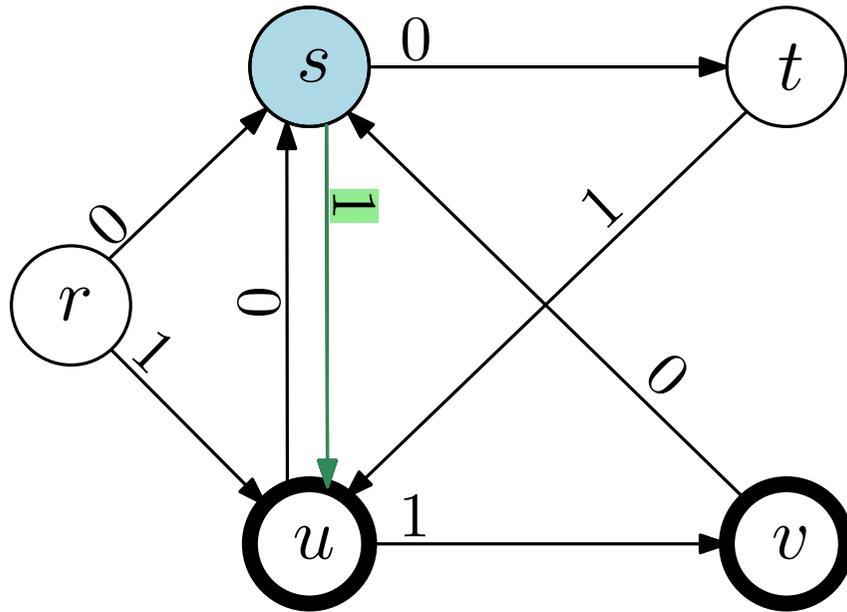


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

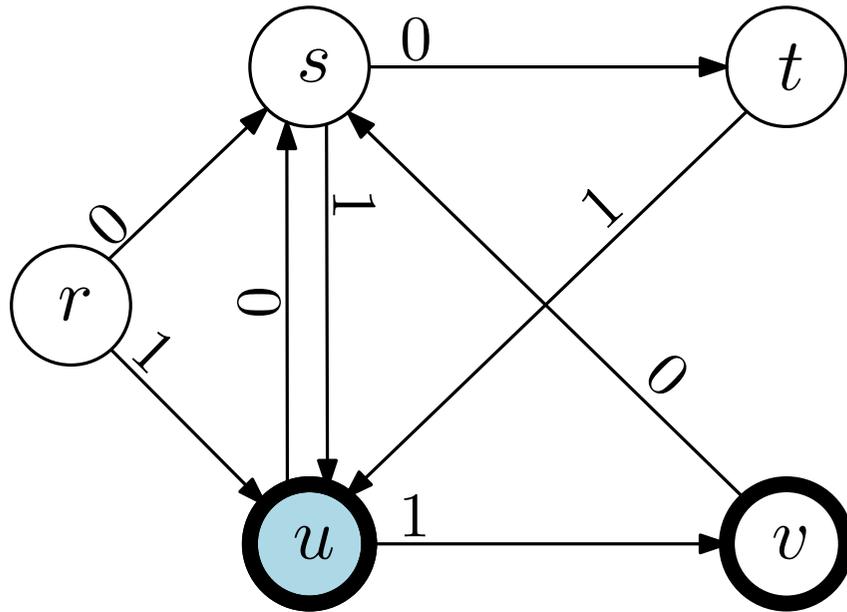


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

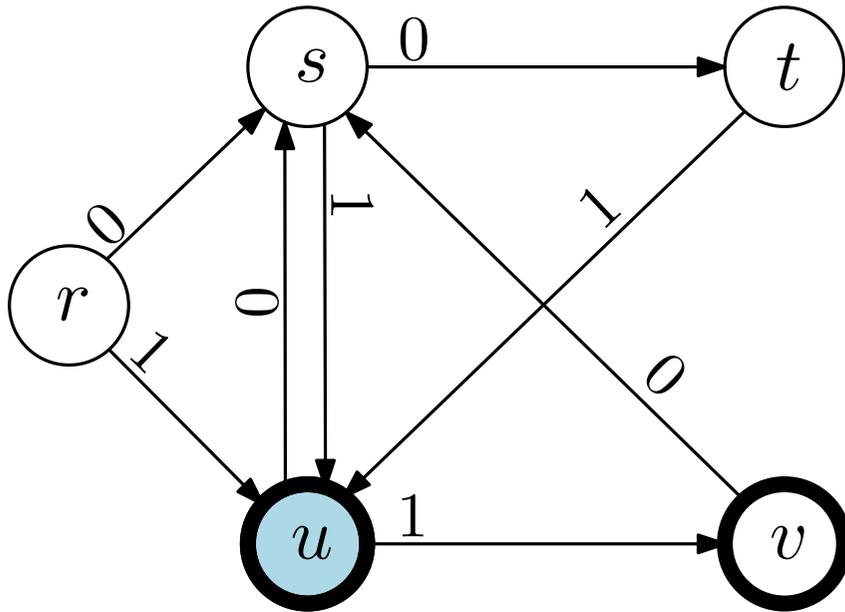


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101

# Exempel 1

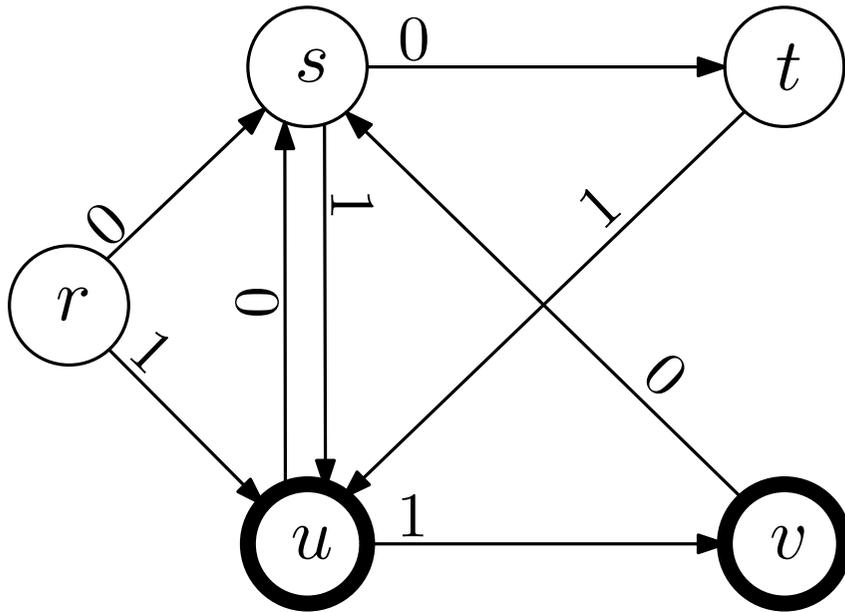


Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101    Slutar i tillstånd  $u$  – strängen accepteras

# Exempel 1



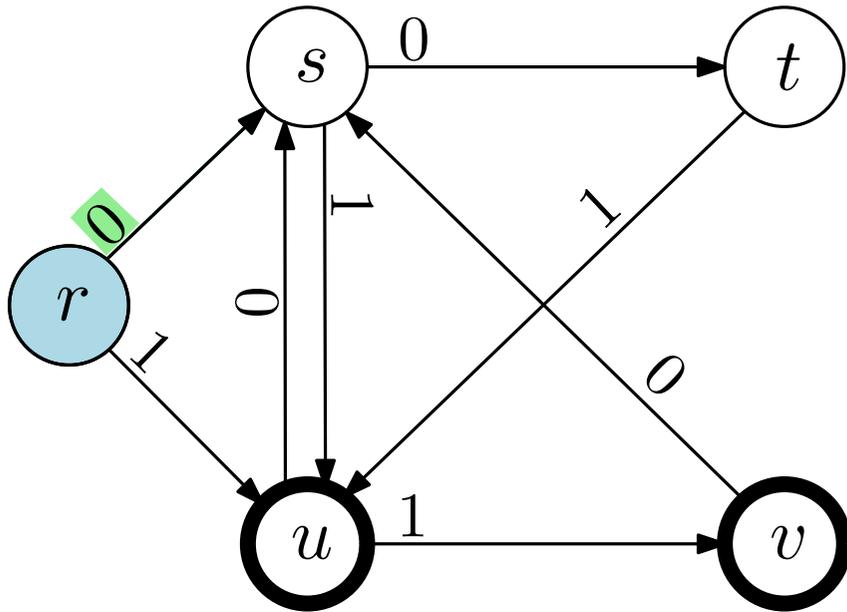
Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101

# Exempel 1



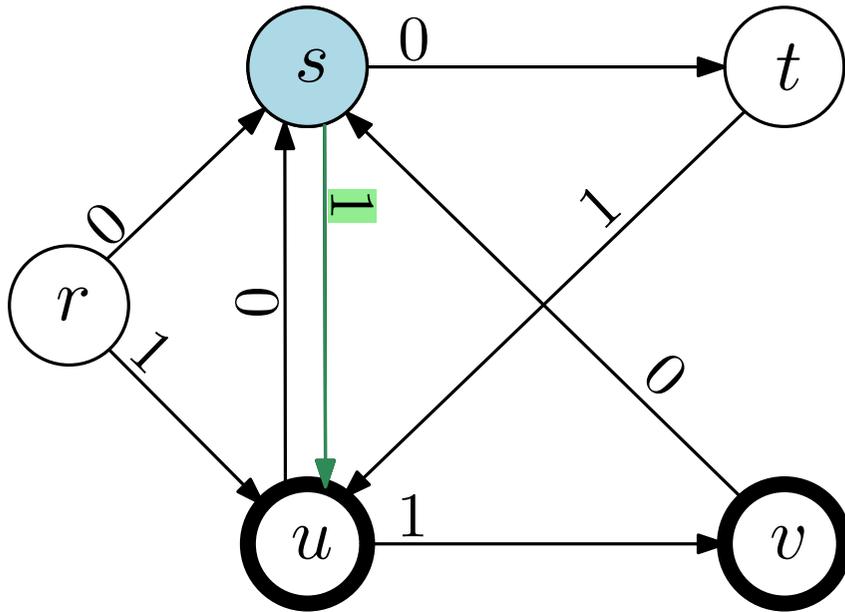
Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101

# Exempel 1



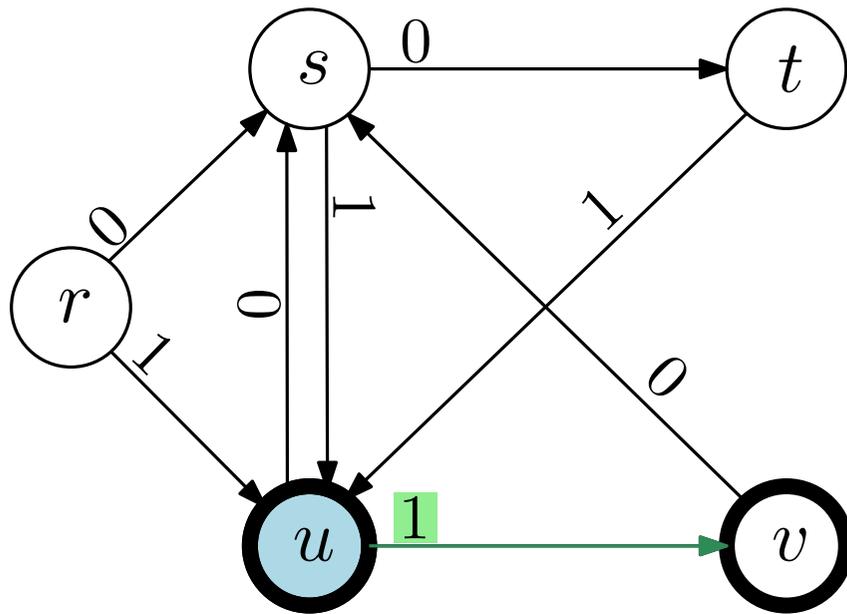
Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101

# Exempel 1



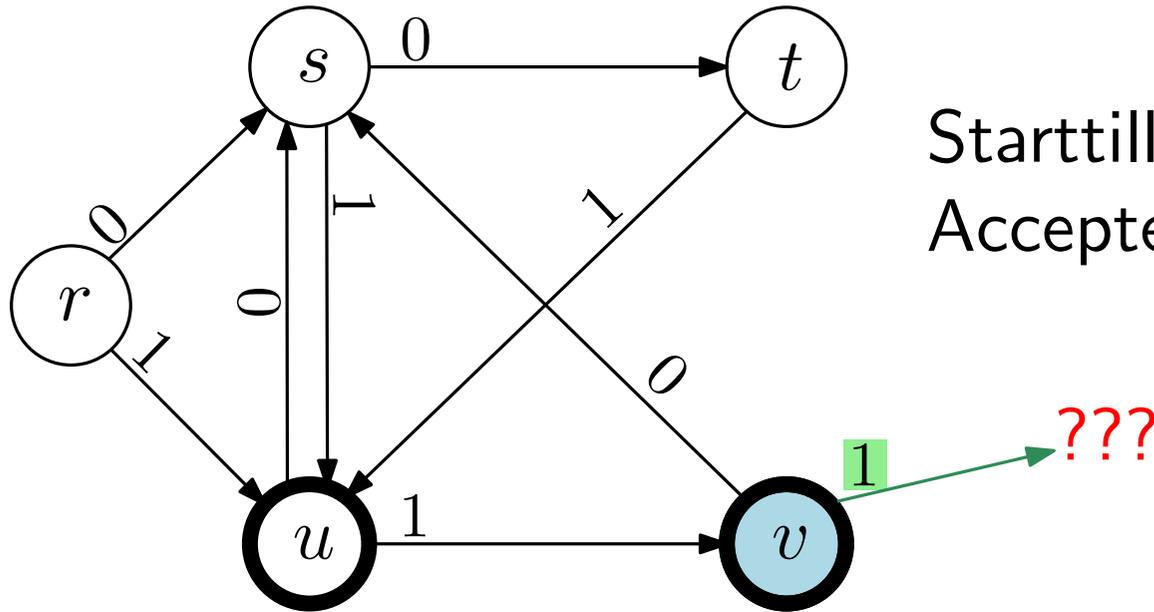
Starttillstånd  $r$

Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101

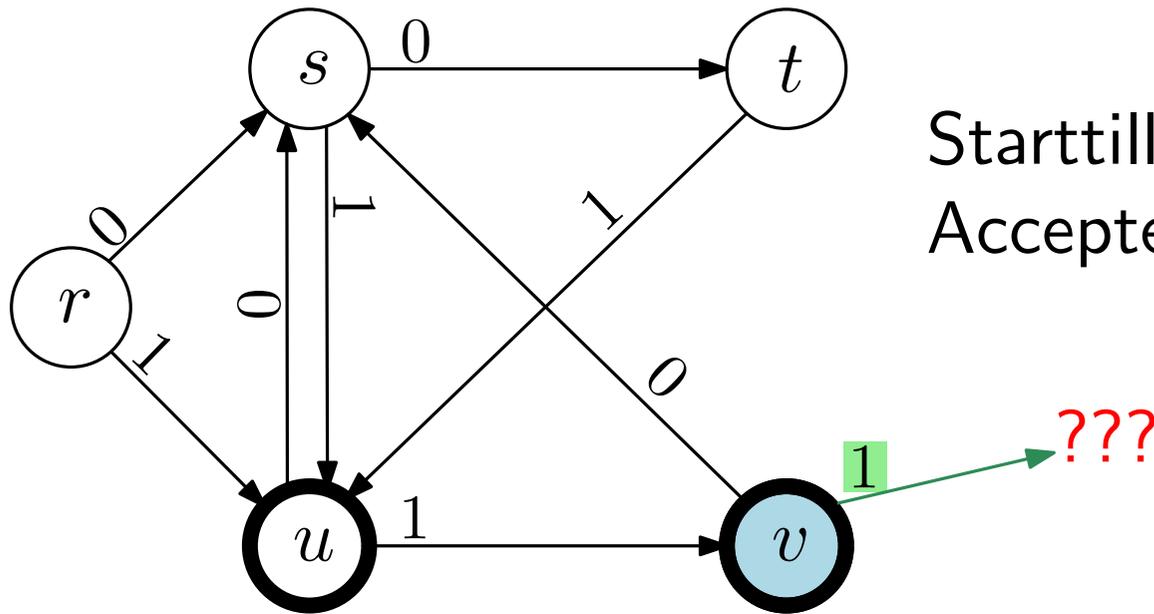
# Exempel 1



Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101

# Exempel 1



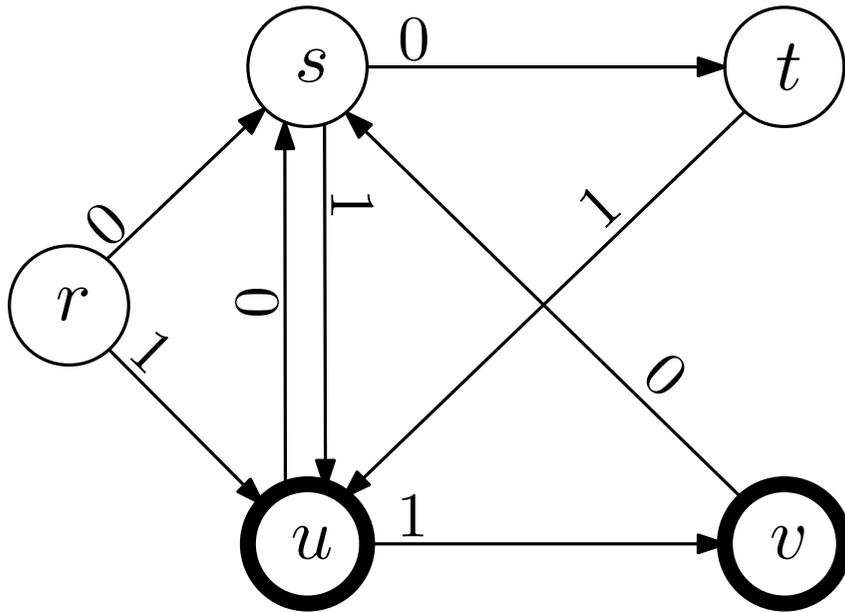
Indata: 01100101

Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101

Övergång saknas – strängen accepteras ej  
(underförstått: implicit 1-övergång från  $v$  till ett “fail”-tillstånd där vi ligger och snurrar och aldrig kan komma tillbaka till ett accepterande tillstånd)

# Exempel 1



Starttillstånd  $r$

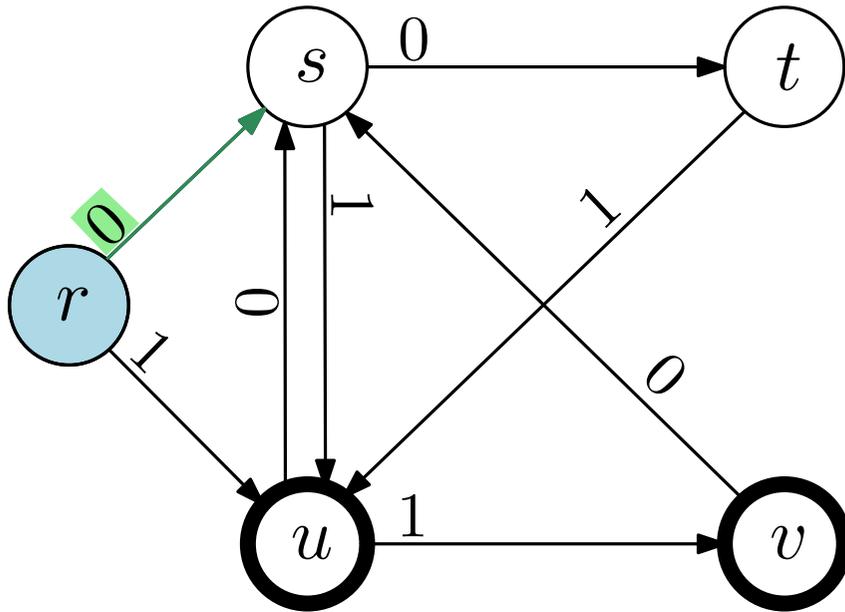
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

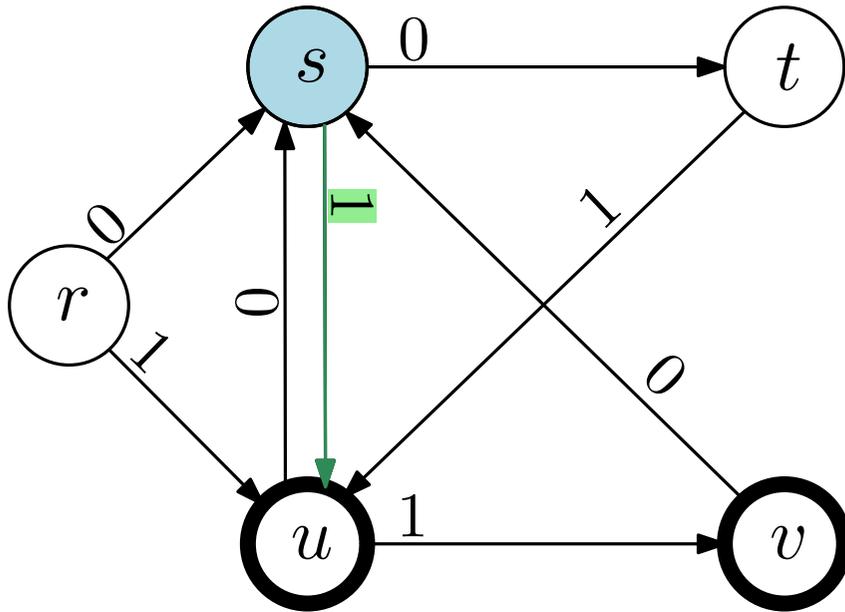
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

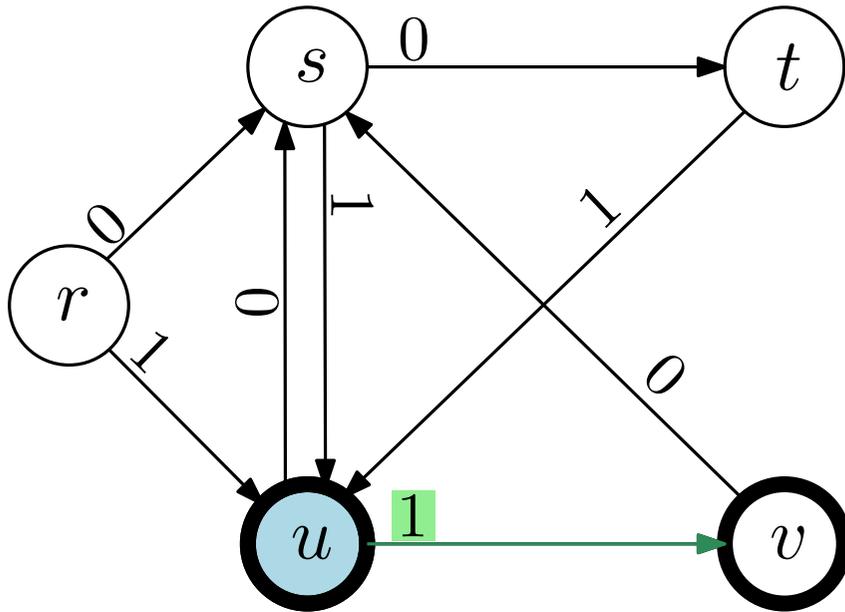
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

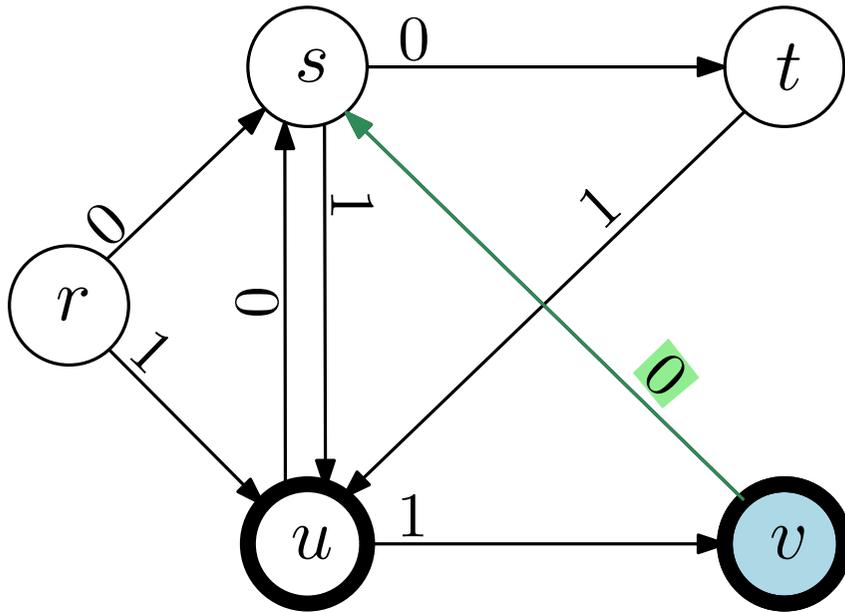
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

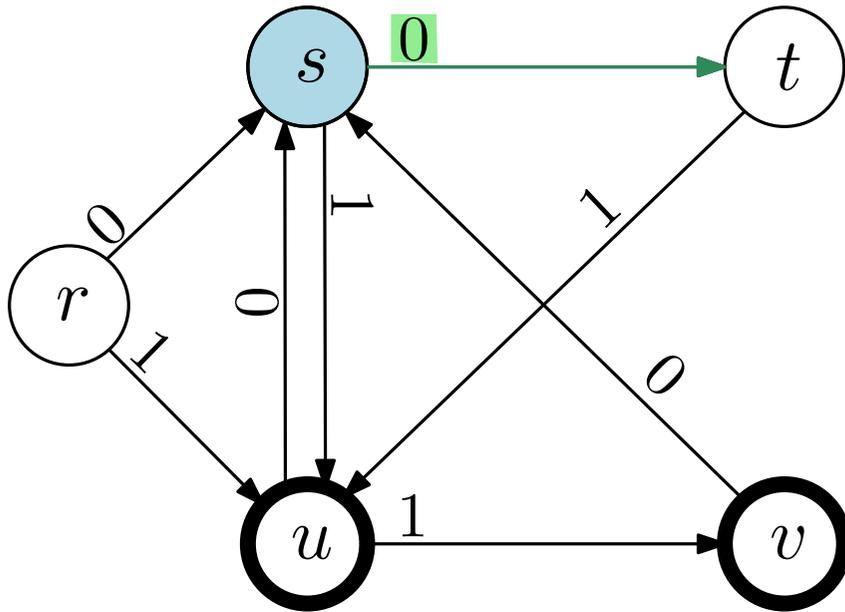
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

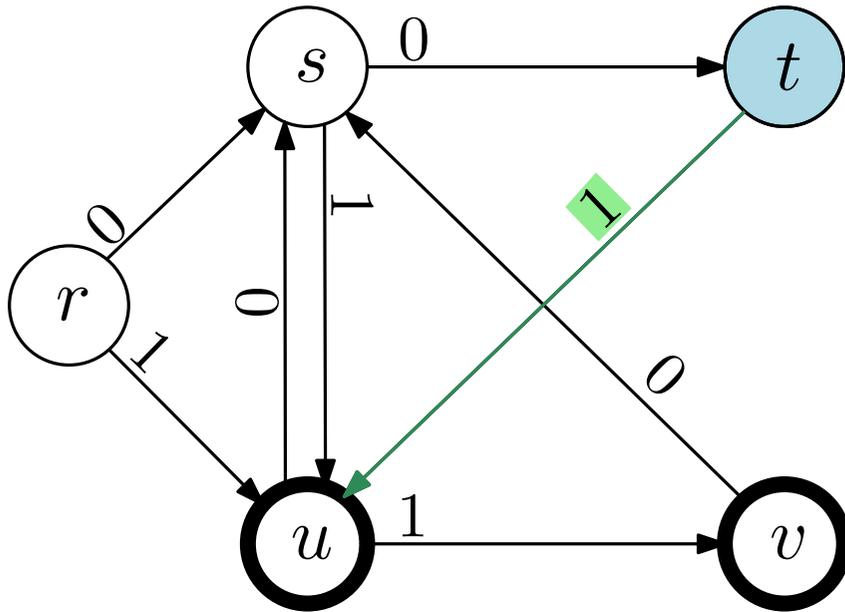
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

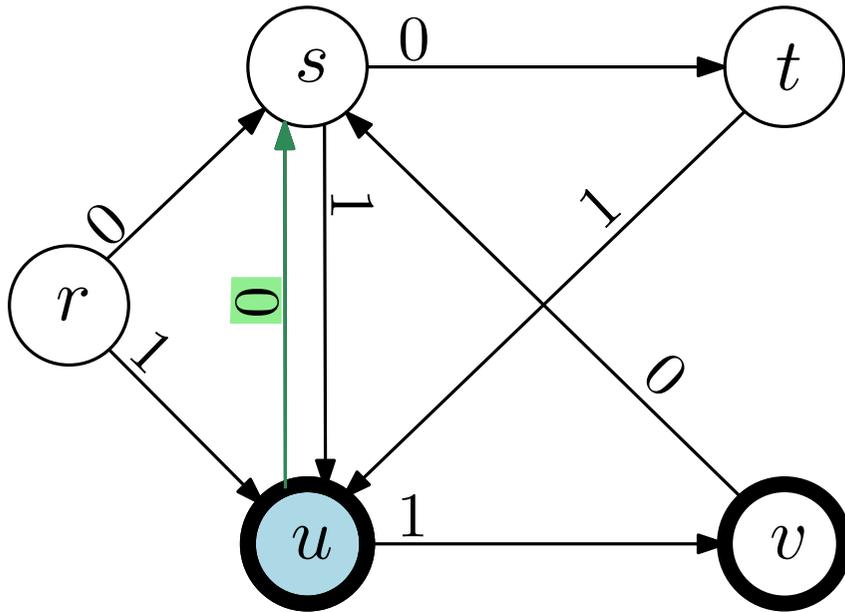
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

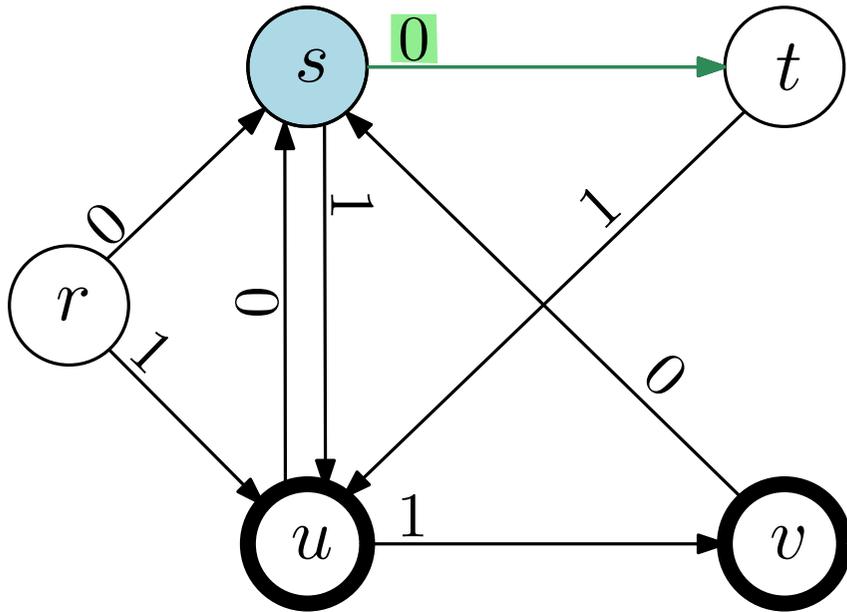
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

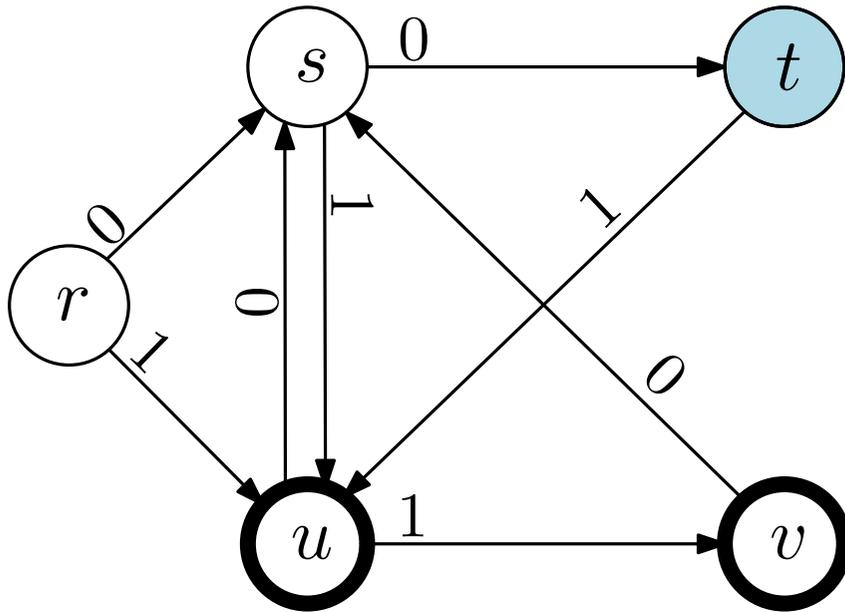
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

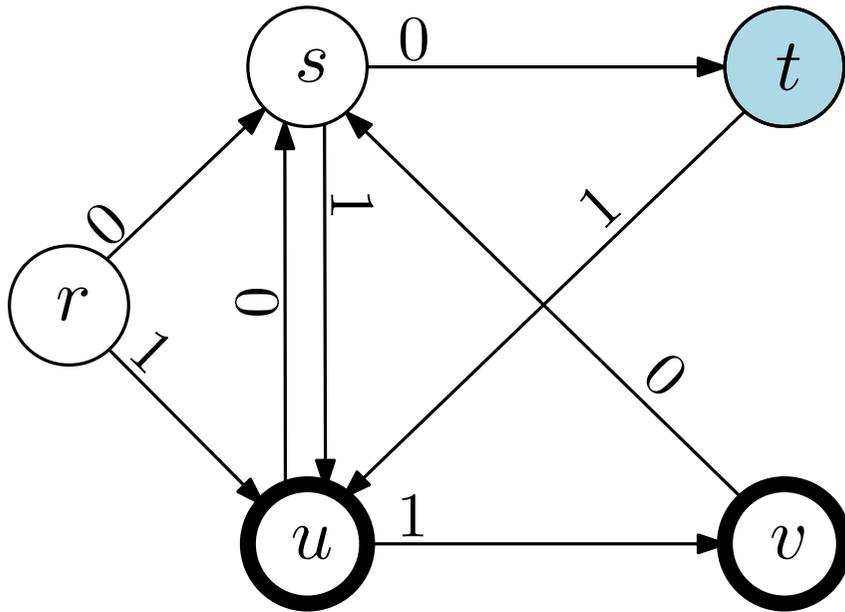
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

Indata: 01100100

# Exempel 1



Starttillstånd  $r$

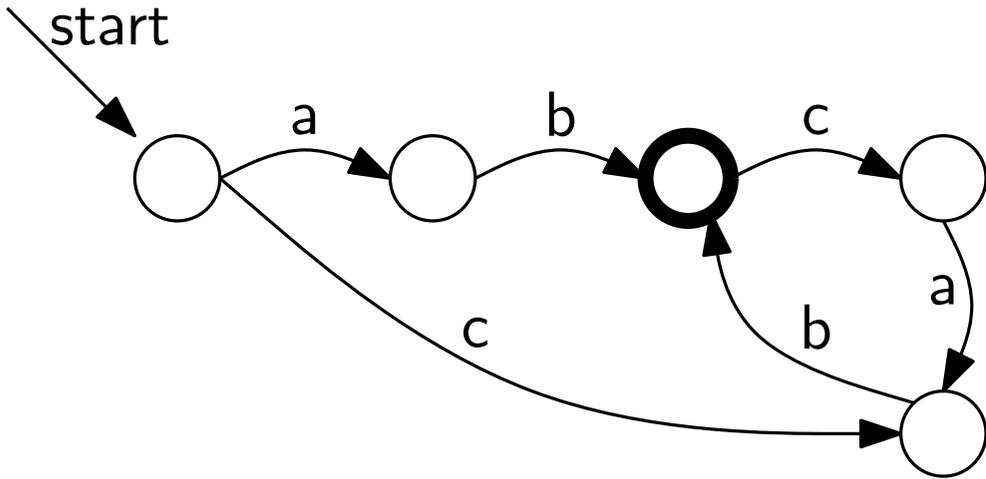
Accepterande tillstånd  $u$  och  $v$

Indata: 01100101      Slutar i tillstånd  $u$  – strängen accepteras

Indata: 01110101      Övergång saknas – strängen accepteras ej

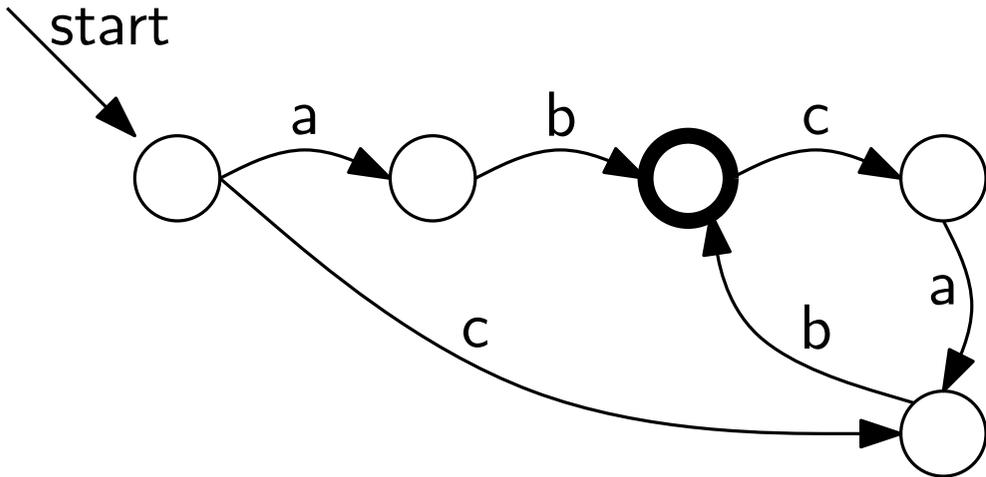
Indata: 01100100      Slutar i tillstånd  $t$  – strängen accepteras ej

## Exempel 2



Hur hitta några exempel på strängar som automaten accepterar?

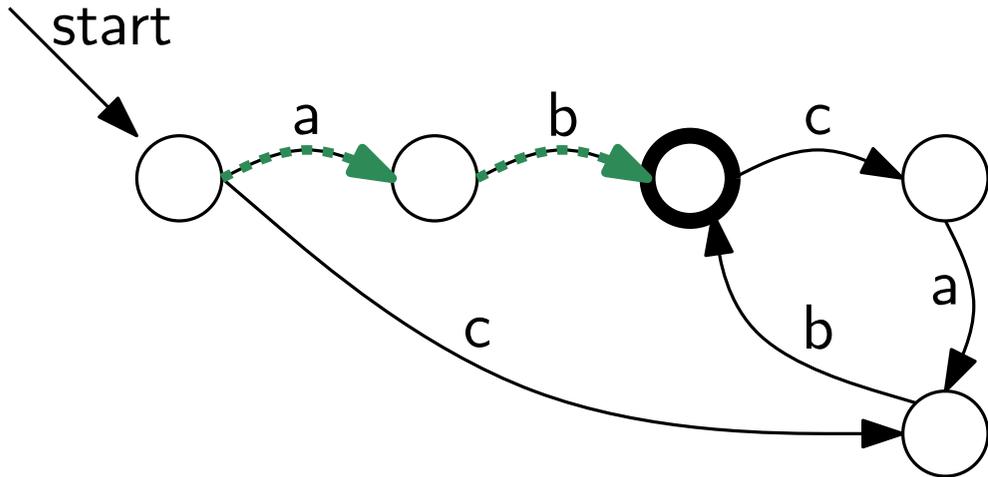
## Exempel 2



Hur hitta några exempel på strängar som automaten accepterar?

Följ pilarna och hitta en väg till ett accepterande tillstånd!

## Exempel 2



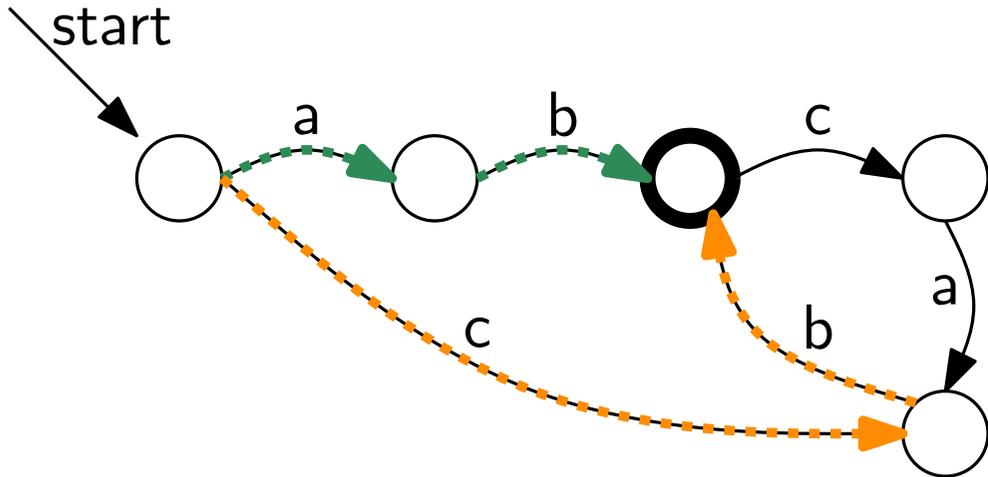
Hur hitta några exempel på strängar som automaten accepterar?

Följ pilarna och hitta en väg till ett accepterande tillstånd!

Automaten accepterar:

**ab**

## Exempel 2



Hur hitta några exempel på strängar som automaten accepterar?

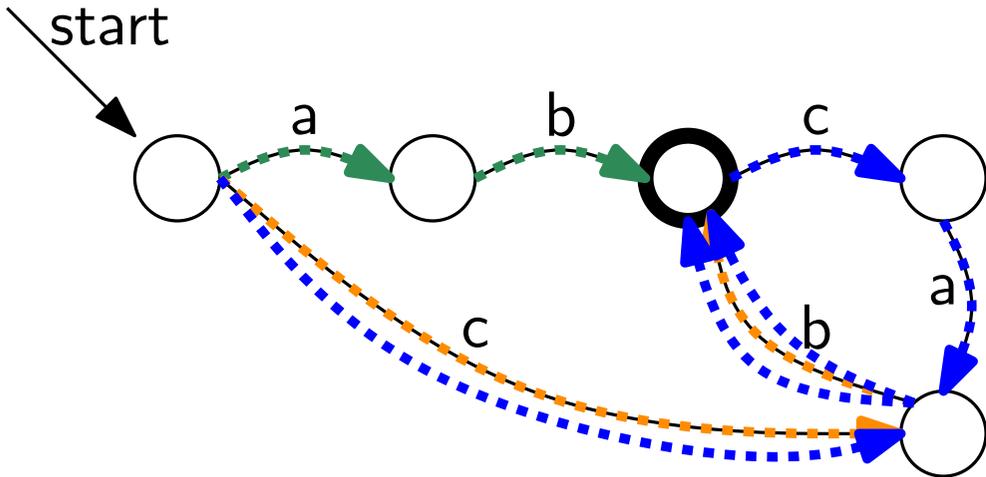
Följ pilarna och hitta en väg till ett accepterande tillstånd!

Automaten accepterar:

ab

cb

## Exempel 2



Hur hitta några exempel på strängar som automaten accepterar?

Följ pilarna och hitta en väg till ett accepterande tillstånd!

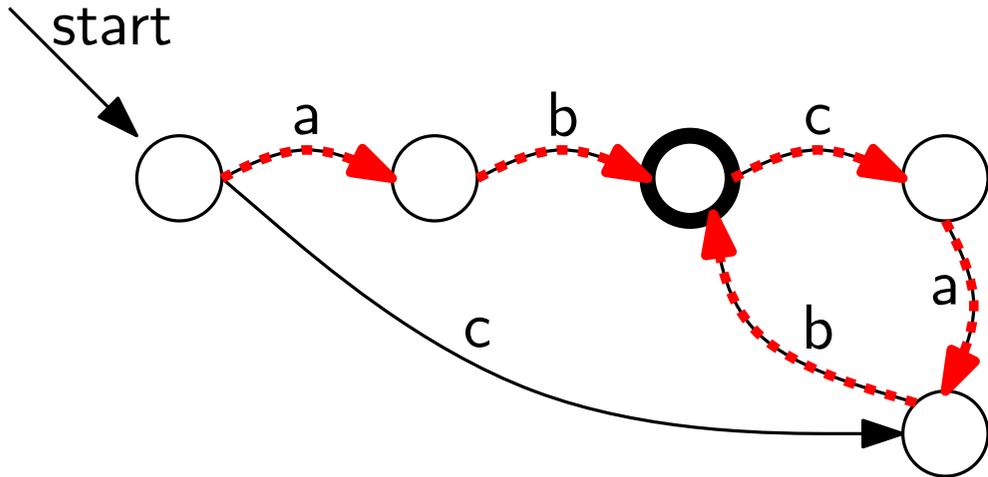
Automaten accepterar:

ab

cb

cbcab

## Exempel 2



Hur hitta några exempel på strängar som automaten accepterar?

Följ pilarna och hitta en väg till ett accepterande tillstånd!

Automaten accepterar:

ab

cb

cbcab

abcab

abcabcbcabcbcab

...

Idag

Reguljära uttryck

Ändliga automater

Formella språk

Några praktiska exempel

# Formella språk

Ett *formellt språk*  $L$  är en mängd strängar.

- $L = \{\text{java, haskell, prolog}\}$
- 8-bitars binära tal:  
 $L = \{0, 1\}^8$
- Alla binära strängar med udda paritet:  
 $L = \{w \in \{0, 1\}^* \mid \text{udda antal ettor i } w\}$
- Alla primtal skrivna som siffersträngar i bas 10,  
 $L = \{2, 3, 5, 7, 11, \dots\}$
- Satisfierbara Booleska formler
- Syntaktiskt korrekta Javaprogram

# Att beskriva ett formellt språk

Ett formellt språk kan definieras / specificeras / beskrivas på många olika sätt:

# Att beskriva ett formellt språk

Ett formellt språk kan definieras / specificeras / beskrivas på många olika sätt:

- Räkna upp strängarna i språket (om språket är ändligt)  
 $L = \{\text{Inet}, F1, F2, L1, L2, S1, S2\}$

# Att beskriva ett formellt språk

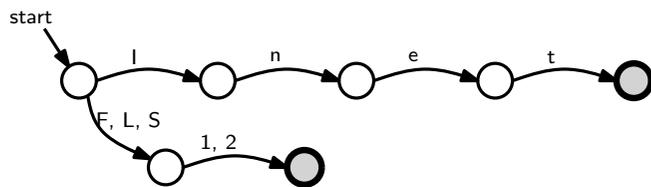
Ett formellt språk kan definieras / specificeras / beskrivas på många olika sätt:

- Räkna upp strängarna i språket (om språket är ändligt)  
 $L = \{Inet, F1, F2, L1, L2, S1, S2\}$
- Ge regler för hur strängar som tillhör språket måste se ut  
Inet | [FLS] [12]  
 $[A-Za-z0-9] ([A-Za-z0-9.]^* [A-Za-z0-9])?@[a-z0-9]+(\.[a-z0-9]+)^+$

# Att beskriva ett formellt språk

Ett formellt språk kan definieras / specificeras / beskrivas på många olika sätt:

- Räkna upp strängarna i språket (om språket är ändligt)  
 $L = \{Inet, F1, F2, L1, L2, S1, S2\}$
- Ge regler för hur strängar som tillhör språket måste se ut  
 $Inet | [FLS] [12]$   
 $[A-Za-z0-9] ([A-Za-z0-9.]^* [A-Za-z0-9])?@[a-z0-9]+(\.[a-z0-9]+)^+$
- Konstruera en algoritm som avgör huruvida en sträng tillhör språket eller inte (dvs "känner igen" språket)

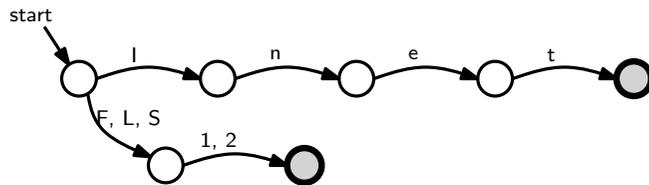


```
for i = 2 to n-1
  if n mod i == 0
    return false
return true
```

# Att beskriva ett formellt språk

Ett formellt språk kan definieras / specificeras / beskrivas på många olika sätt:

- Räkna upp strängarna i språket (om språket är ändligt)  
 $L = \{Inet, F1, F2, L1, L2, S1, S2\}$
- Ge regler för hur strängar som tillhör språket måste se ut  
 $Inet | [FLS] [12]$   
 $[A-Za-z0-9] ([A-Za-z0-9.]^* [A-Za-z0-9])?@[a-z0-9]+(\.[a-z0-9]+)^+$
- Konstruera en algoritm som avgör huruvida en sträng tillhör språket eller inte (dvs "känner igen" språket)



```
for i = 2 to n-1
  if n mod i == 0
    return false
return true
```

- Ge en informell definition  
"mängden av alla Java-program som har en oändlig loop"

# Den teoretiska delen om formella språk

Hur går man från en informell eller icke-konstruktiv definition till regler eller algoritmer för att känna igen språket?

# Den teoretiska delen om formella språk

Hur går man från en informell eller icke-konstruktiv definition till regler eller algoritmer för att känna igen språket?

T.ex.:

- Vilka typer av språk kan man beskriva med ett reguljärt uttryck?
- Vad är den effektivaste algoritmen för att avgöra om ett tal är ett primtal?

# Den teoretiska delen om formella språk

Hur går man från en informell eller icke-konstruktiv definition till regler eller algoritmer för att känna igen språket?

T.ex.:

- Vilka typer av språk kan man beskriva med ett reguljärt uttryck?
- Vad är den effektivaste algoritmen för att avgöra om ett tal är ett primtal?

Detta är grunden till forskningsområdet “teoretisk datalogi”

(Den typ av frågor vi kommer titta på i den här kursen är grundläggande frågor som man löst för 50+ år sedan och inte så forskningsnära.)

Idag

Reguljära uttryck

Ändliga automater

Formella språk

Reguljära uttryck i praktiken

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

Minsta gemensamma nämnaren är *POSIX-standard* för reguljära uttryck.

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

Minsta gemensamma nämnaren är *POSIX-standard* för reguljära uttryck.

Det är också vanligt med extra funktionalitet som inte kan simuleras med “riktiga” reguljära uttryck

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

Minsta gemensamma nämnaren är *POSIX-standard* för reguljära uttryck.

Det är också vanligt med extra funktionalitet som inte kan simuleras med “riktiga” reguljära uttryck

Typ-exempel: *bakåtreferenser* `(.*) (.*)\2\1`

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

Minsta gemensamma nämnaren är *POSIX-standard* för reguljära uttryck.

Det är också vanligt med extra funktionalitet som inte kan simuleras med “riktiga” reguljära uttryck

Typ-exempel: *bakåtreferenser* `(.*) (.*)\2\1`

`\n` betyder “samma sträng som vi matchade med den *n*:te parentes-gruppen”

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

Minsta gemensamma nämnaren är *POSIX-standard* för reguljära uttryck.

Det är också vanligt med extra funktionalitet som inte kan simuleras med “riktiga” reguljära uttryck

Typ-exempel: *bakåtreferenser* `(.*) (.*)\2\1`

`\n` betyder “samma sträng som vi matchade med den *n*:te parentes-gruppen”

Matchar t.ex. abba, `erbananerb`

# Reguljära uttryck i praktiken – Regex

Det finns många olika mindre variationer på syntax för reguljära uttryck mellan olika implementationer

Minsta gemensamma nämnaren är *POSIX-standarden* för reguljära uttryck.

Det är också vanligt med extra funktionalitet som inte kan simuleras med “riktiga” reguljära uttryck

Typ-exempel: *bakåtreferenser* `(.*) (.*)\2\1`

Tyvärr ganska stor begreppsförvirring: “reguljärt uttryck” kan betyda olika beroende på om man åsyftar teorin för formella språk, eller det praktiska verktyget för strängmatchning

## **Terminologi i kursen:**

Det vi beskrev tidigare = “reguljärt uttryck”

Med utökningar som bakåtreferenser = “regex”

# Regex i Unix

```
> grep '<regex>' <fil>
```

visa alla rader i <fil> där något som matchar <regex>

förekommer (variant: egrep, använder annan regex-dialekt)

# Regex i Unix

```
> grep '<regex>' <fil>
```

visa alla rader i <fil> där något som matchar <regex> förekommer (variant: egrep, använder annan regex-dialekt)

## Exempel:

```
> grep "a..str" pride_and_prejudice.txt
```

```
united, with great strength of feeling, a composure of temper and a  
commission of the peace of the county, she was a most active magistrate  
of his mind was visible in every feature. He was struggling for the  
am strongly inclined to hope the best. Could he expect that her friends
```

# Regex i Unix

```
> grep '<regex>' <fil>
```

visa alla rader i <fil> där något som matchar <regex> förekommer (variant: egrep, använder annan regex-dialekt)

## Exempel:

```
> grep "a..str" pride_and_prejudice.txt
```

```
united, with great strength of feeling, a composure of temper and a  
commission of the peace of the county, she was a most active magistrate  
of his mind was visible in every feature. He was struggling for the  
am strongly inclined to hope the best. Could he expect that her friends
```

```
> sed 's/<regex>/<replacement>/g' < <fil>
```

byter ut alla förekomster av <regex> mot <replacement>

# Regex i Unix

```
> grep '<regex>' <fil>
```

visa alla rader i <fil> där något som matchar <regex> förekommer (variant: egrep, använder annan regex-dialekt)

## Exempel:

```
> grep "a..str" pride_and_prejudice.txt
```

```
united, with great strength of feeling, a composure of temper and a  
commission of the peace of the county, she was a most active magistrate  
of his mind was visible in every feature. He was struggling for the  
am strongly inclined to hope the best. Could he expect that her friends
```

```
> sed 's/<regex>/<replacement>/g' < <fil>
```

byter ut alla förekomster av <regex> mot <replacement>

## Exempel:

```
sed 's/Darcy/Austrin/g' < pride_and_prejudice.txt > my_novel.txt
```

# Regex i Unix

```
> grep '<regex>' <fil>
```

visa alla rader i <fil> där något som matchar <regex> förekommer (variant: egrep, använder annan regex-dialekt)

## Exempel:

```
> grep "a..str" pride_and_prejudice.txt
```

```
united, with great strength of feeling, a composure of temper and a  
commission of the peace of the county, she was a most active magistrate  
of his mind was visible in every feature. He was struggling for the  
am strongly inclined to hope the best. Could he expect that her friends
```

```
> sed 's/<regex>/<replacement>/g' < <fil>
```

byter ut alla förekomster av <regex> mot <replacement>

## Exempel:

```
sed 's/Darcy/Austrin/g' < pride_and_prejudice.txt > my_novel.txt
```

...och många fler Unix-verktyg!

# Regex i Java

Finns i paketet `java.util.regex`

# Regex i Java

Finns i paketet `java.util.regex`

**Kolla om en sträng matchar ett uttryck:**

```
import java.util.regex.Pattern;

public boolean isValidEmail(String address) {
    return Pattern.matches(regex_for_email, address);
}
```

# Regex i Java

Finns i paketet `java.util.regex`

## Kolla om en sträng matchar ett uttryck:

```
import java.util.regex.Pattern;

public boolean isValidEmail(String address) {
    return Pattern.matches(regex_for_email, address);
}
```

## Ersätta hundar med katter:

```
import java.util.regex.*;

Pattern p = Pattern.compile("cat");
Matcher m = p.matcher("one cat, two cats in the yard");
String s = m.replaceAll("dog");
// --> s = "one dog, two dogs in the yard"
```

# Regex i Haskell

## Ersätta hundar med katter

```
module Replace where
import Text.Regex
```

```
replacement = subRegex re s1 "cat"
  where re = mkRegex "dog"
        s1 = "one dog, two dogs in the yard"
```

# Regex i Haskell

## Ersätta hundar med katter

```
module Replace where
import Text.Regex
```

```
replacement = subRegex re s1 "cat"
  where re = mkRegex "dog"
        s1 = "one dog, two dogs in the yard"
```

## Provkörning

```
> ghci Replace.hs
```

```
...
```

```
*Replace> replacement
```

```
...
```

```
"one cat, two cats in the yard"
```

## Regex i Haskell, forts

**Dela opp en text med avseende på ett regex**

```
module Split where
import Text.Regex
```

```
split s = splitRegex nonletters s
  where nonletters = mkRegex "[^a-zA-Z]+"
```

## Regex i Haskell, forts

### **Dela upp en text med avseende på ett regex**

```
module Split where
import Text.Regex
```

```
split s = splitRegex nonletters s
  where nonletters = mkRegex "[^a-zA-Z]+"
```

### **Provkörning**

```
> ghci Split.hs
```

```
...
```

```
*Split> split "One, two, three, and 4 balloons!"
```

```
...
```

```
["One", "two", "three", "and", "balloons", ""]
```

# Regex i andra språk

Vi skulle kunna hålla på och gå igenom hur man använder regex i olika språk i flera timmar, men det blir snabbt tråkigt.

När man vill använda regex i sitt favorit-språk kollar man dokumentationen för språket hur regex fungerar där, exakt vilken notation som används osv

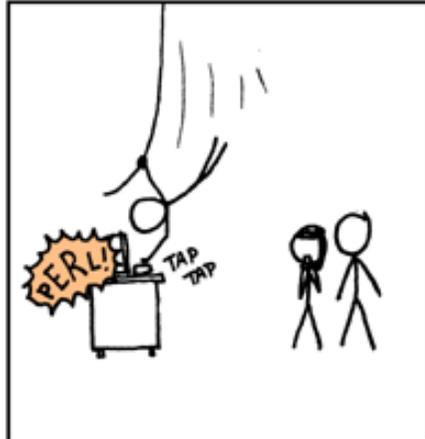
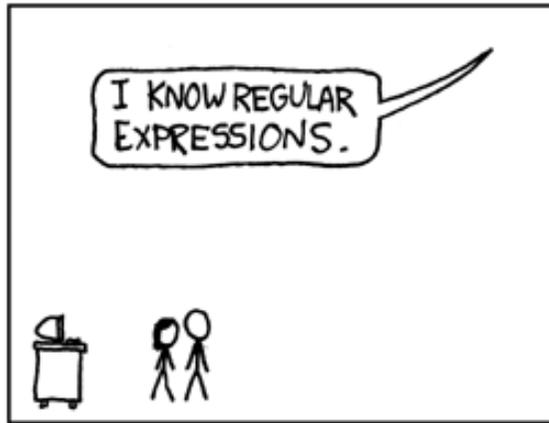
(typiskt brukar det gå bra att googla på  
“<programspråk> regular expressions” ...)

På fredag

**Mer om reguljära uttryck och ändliga automater:**  
ekvivalens och begränsningar

**Mer kraftfulla sätt att beskriva språk:**  
grammatiker och stackautomater

WHENEVER I LEARN A NEW SKILL I CONCOCT ELABORATE FANTASY SCENARIOS WHERE IT LETS ME SAVE THE DAY.



xkcd #208, Randall Munroe