IN1140: Introduksjon til språkteknologi

Forelesning #4

Egil Rønningstad

Universitetet i Oslo

11. september 2023



Tema for i dag

- Regulære uttrykk

Tema for i dag

- Regulære uttrykk



https://imgs.xkcd.com/comics/regular_expressions.png

Dagens leksjon



- Presentere regulære uttrykk
- Motivasjon for å mestre verktøyet: Blir brukt for å spesifisere tekststrenger i all slags type tekstprosessering og informasjonsutvinning
- Introduksjon til verktøyet
- Regex læres gjennom å bruke verktøyet. Dagens forelesning skal bare hjelpe deg i gang.
- Hele kapittel 2.1 er pensum, også substitusjon, capture-grupper og lookahead.
- Når uttrykkene blir litt kompliserte, kan det være forskjeller mellom Python-implemetasjonen og "ren" (PEARL?) regex. På eksamen blir du ikke spurt om Python-implementasjon.

Regular expressions[1] (called REs, or regexes, or regex patterns) are essentially a tiny, highly specialized programming language embedded inside Python and made available through the re module. Using this little language, you specify the rules for the set of possible strings that you want to match; this set might contain English sentences, or e-mail addresses, or TeX commands, or anything you like. You can then ask questions such as "Does this string match the pattern?", or "Is there a match for the pattern anywhere in this string?". You can also use REs to modify a string or to split it apart in various ways.

[1] `https://docs.python.org/3/howto/regex.html`

Regular expressions[1] (called REs, or regexes, or regex patterns) are essentially a tiny, highly specialized programming language embedded inside Python and made available through the re module. Using this little language, you specify the rules for the set of possible strings that you want to match; this set might contain English sentences, or e-mail addresses, or TeX commands, or anything you like. You can then ask questions such as "Does this string match the pattern?", or "Is there a match for the pattern anywhere in this string?". You can also use REs to modify a string or to split it apart in various ways.

[1] `https://docs.python.org/3/howto/regex.html`

Kraftfullt og krevende

If you've ever talked about regular expressions with another programmer, you've invariably heard this 1997 chestnut:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.

The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.

https://blog.codinghorror.com/regular-expressions-now-you-have-two-problems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`/problem/`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`/problem/`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`/[Pp]roblem/`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`/[Pp]roblem/`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`/[Pp]roblems?/`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`/[Pp]roblems?/`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`\b[Pp]roblems?\b`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Kraftfullt og krevende

Oppgave: Matche alle ord "Problem" i entall eller flertall, begynnelsen av setning eller inni, ikke som del av sammensatte former.

`\b[Pp]roblems?\b`

Problems and regular expressions to fix them:
Some people, when confronted with a problem, think "I know, I'll use regular expressions." Now they have two problems.
The quote is from Jamie Zawinski, a world class hacker who I admire greatly. ... Here's the point Jamie was trying to make: not that regular expressions are evil, per se, but that overuse of regular expressions is evil. ... I couldn't agree more. Regular expressions are like a particularly spicy hot sauce – to be used in moderation and with restraint only when appropriate. Should you try to solve every problem you encounter with a regular expression? Well, no. Then you'd be writing Perl, and I'm not sure you need those kind of headaches. If you drench your plate in hot sauce, you're going to be very, very sorry later.
https://blog.codinghorror.com/regular-expressions-nowyouhavetwoproblems/

Definisjon

- Regulære uttrykk:
  - Standard notasjon for å karakterisere tekstsekvenser
  - Blir brukt for å spesifisere tekststrenger i all slags type tekstprosessering og informasjonsutvinning

Noen applikasjonseksempler

- Tokenisering
- Tekstprosessering (finne, erstatte)
  - Finne alle telefonnumre i en tekst, feks:
    - *Du kan også ringe Kundeservice på* **815 22 040**
    - *Du kan også ringe Kundeservice på* **815 22 041**
    - *Du kan også ringe Kundeservice på* **815 22 501**
  - Finne flere tilgrensende instanser av samme ord i en tekst
- Bestemme språket i en setning/tekst: spansk eller polsk?
  - *Sytuacja na Bliskim Wschodzie jest napieta, szczegolnie po wczorajszym ataku*

Noen applikasjonseksempler

- Validere felter i en database (datoer, e-postadresser, URL'er)
- Søk i et korpus etter lingvistiske mønstre
  - samle statistikk
- Tildele ordklasse til disse, selv om de ikke fins i ordboken. F.eks.:
  - *conurbation, cadence, disproportionality, Thatcherization*

Noen applikasjonseksempler

- Utstrakt bruk innenfor:
  - informasjonshenting ("information extraction"), f.eks. navn på personer og firmaer
  - automatisk morfologisk analyse

Regulære uttrykk

- Et regulært uttrykk er en beskrivelse av en mengde strenger
- Finnes en rekke UNIX-verktøy (grep, sed), editorer (emacs) og progammeringsspråk (perl, python, java) som har funksjonalitet for regulære uttrykk
- Som alle formalismer har ikke regulære uttrykk noe språklig (lingvistisk) innhold, men kan snarere brukes til å referere til lingvistiske enheter

Regulære uttrykk (RU)

To slags tegn ("characters"):

- **Bokstaver**
  - ethvert teksttegn er et RU og refererer til seg selv
- **Meta-tegn**
  - spesialtegn som lar deg kombinere RU på forskjellige måter
- Eksempel:
  - /a/ refererer til a
  - /a*/ refererer til ϵ (null) eller a eller aa eller aaa eller ...

Regulære uttrykk (RU)

To slags tegn ("characters"):

- **Bokstaver**
  - ethvert teksttegn er et RU og refererer til seg selv
- **Meta-tegn**
  - spesialtegn som lar deg kombinere RU på forskjellige måter
- Eksempel:
  - /a/ refererer til a
  - /a*/ refererer til ϵ (null) eller a eller aa eller aaa eller ...
- MERK: // (i feks /a/) er **ikke** en del av et RU. Brukes som notasjon for å gjøre det tydelig hva som er RU og hva som ikke er RU

Regulære uttrykk

Regulære uttrykk består av:

- Strenger bestående av tegn: `/b/`, `/IN1140/`, `/informatikk/`
- Disjunksjon:
  - vanlig disjunksjon: `/spise|ete/`, `/penge(r|ne)/`
  - tegnklasser:`/[Dd]en/`, `/m[ae]nn/`, `/bec[oa]me/`
  - intervaller ("ranges"): `[A-Z]`, `[a-z]`, `[0-9]`
- Negasjon:
  - Bruk av `^`
  - `[^b]`
  - `[^A-Z0-9]`

Regulære uttrykk

Regulære uttrykk består av:

- Strenger bestående av tegn: `/b/`, `/IN1140/`, `/informatikk/`
- Disjunksjon:
  - vanlig disjunksjon: `/spise|ete/`, `/penge(r|ne)/`
  - tegnklasser:`/[Dd]en/`, `/m[ae]nn/`, `/bec[oa]me/`
  - intervaller ("ranges"): `[A-Z]`, `[a-z]`, `[0-9]`
- Negasjon:
  - Bruk av `^`
  - `[^b]`
  - `[^A-Z0-9]`
  - `a\^b` ser etter sekvensen "a^b" i en streng
    - feks: "se etter `a^b` nå"
  - `e\^` ser etter sekvensen "e^" i en streng
    - feks: "se etter `e^` nå"

Regulære uttrykk

Regulære uttrykk består av (forts.):

- Tellere
  - opsjonalitet (0 eller 1): `?`
    - `/woodchucks?/` (fanger begge "woodchucks" og "woodchuck")
    - `/colou?r/` (fanger begge "colour" og "color")
  - hvilket som helst antall (0 eller flere): Kleene `*`
    - `/ba*!/` (fanger "b!", "ba!", "baa!", "baaa!", "baaaa!", "baaaaaaaaaa!")
    - `/[1-9][0-9]*/`
  - Minst en: `+`
    - `/ba+!/` (fanger "ba!", "baa!", "baaa!", "baaaa!", "baaaaaaaaaa!")
    - `/[0-9]+ kroner/`

Regulære uttrykk

Regulære uttrykk består av (forts.):

- "wildcard" for et hvilket som helst tegn: .
  - `/beg.n/` (alt som finnes mellom *beg* og *n*)
    - "begin"
    - "beg'n"
    - "begun"
  - brukes ofte sammen med stjerne: "hva som helst":
  - `/beltedyr.*beltedyr/`
    - "beltedyr er en familie av gomlere som er i utgangspunktet en ren søramerikansk gruppe, og Sør-Amerika pluss de sørlige delene av Nord-Amerika er de eneste stedene hvor beltedyr finnes vilt i dag"

Regulære uttrykk

Regulære uttrykk består av (forts.):
Ankere: spesielle tegn som forankrer det regulære uttrykket til spesifikt sted i strengen/teksten

- `^` - begynnelsen av linjen
  - `/^Den/` matcher "Den" bare i begynnelsen av en linje

Regulære uttrykk

Regulære uttrykk består av (forts.):
Ankere: spesielle tegn som forankrer det regulære uttrykket til spesifikt sted i strengen/teksten

- `^` - begynnelsen av linjen
  - `/^Den/` matcher "Den" bare i begynnelsen av en linje
  - `^` har tre mulige bruk:
    - Matche begynnelsen av en linje
    - Indikerer negasjon innefor firkantede parenteser (`[]`) altså tegnklasser
    - Bare karakteren `^`

Regulære uttrykk

Regulære uttrykk består av (forts.):
Ankere: spesielle tegn som forankrer det regulære uttrykket til spesifikt sted i strengen/teksten

- `^` - begynnelsen av linjen
  - `/^Den/` matcher "Den" bare i begynnelsen av en linje
  - `^` har tre mulige bruk:
    - Matche begynnelsen av en linje
    - Indikerer negasjon innefor firkantede parenteser (`[]`) altså tegnklasser
    - Bare karakteren `^`
- `$` - slutten av linjen
  - `/der\.$/` matcher "der." på slutten av en linje
- `/^Det hvite huset\.$/` ?

Regulære uttrykk

Regulære uttrykk består av (forts.):
Ankere: spesielle tegn som forankrer det regulære uttrykket til spesifikt sted i strengen/teksten

- `^` - begynnelsen av linjen
  - `/^Den/` matcher "Den" bare i begynnelsen av en linje
  - `^` har tre mulige bruk:
    - Matche begynnelsen av en linje
    - Indikerer negasjon innefor firkantede parenteser (`[]`) altså tegnklasser
    - Bare karakteren `^`
- `$` - slutten av linjen
  - `/der\.$/` matcher "der." på slutten av en linje
- `/^Det hvite huset\.$/` ?
  - Matcher kun en linje som inneholder frasen "Det hvite huset."

Regulære uttrykk

Regulære uttrykk består av (forts.):

- Ankere `\b` og `\B`
- `\b` matcher en "word boundary" (altså ordgrense)
  - `/\bthe\b/` matcher ordet "the" men ikke "other"
- `\B` matcher en "non-boundary"

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter “katter” og “hunder” i en tekst:

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter “katter” og “hunder” i en tekst:
  - Kan ikke bruke “[” og “]” for å søke for “katter **eller** hunder”

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter "katter" og "hunder" i en tekst:
  - Kan ikke bruke "[" og "]" for å søke for "katter **eller** hunder"
  - Må bruke **disjunksjon**: `/katter|hunder/`
- Ser etter "guppy" og "guppies":

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter "katter" og "hunder" i en tekst:
  - Kan ikke bruke "[" og "]" for å søke for "katter **eller** hunder"
  - Må bruke **disjunksjon**: `/katter|hunder/`
- Ser etter "guppy" og "guppies":
  - Kan vi si `/guppy|ies/`?

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter "katter" og "hunder" i en tekst:
  - Kan ikke bruke "[" og "]" for å søke for "katter **eller** hunder"
  - Må bruke **disjunksjon**: `/katter|hunder/`
- Ser etter "guppy" og "guppies":
  - Kan vi si `/guppy|ies/`?
    - Nei! Vil matche strengene "guppy" og "ies"

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter "katter" og "hunder" i en tekst:
  - Kan ikke bruke "[" og "]" for å søke for "katter **eller** hunder"
  - Må bruke **disjunksjon**: `/katter|hunder/`
- Ser etter "guppy" og "guppies":
  - Kan vi si `/guppy|ies/`?
    - Nei! Vil matche strengene "guppy" og "ies"
    - Sekvensen `guppy` har **presedens** over disjunksjonen "`|`"

Regulære uttrykk

Disjunksjon, gruppering, og presedens:

- Ser etter "katter" og "hunder" i en tekst:
  - Kan ikke bruke "[" og "]" for å søke for "katter **eller** hunder"
  - Må bruke **disjunksjon**: `/katter|hunder/`
- Ser etter "guppy" og "guppies":
  - Kan vi si `/guppy|ies/`?
    - Nei! Vil matche strengene "guppy" og "ies"
    - Sekvensen guppy har **presedens** over disjunksjonen "|"
  - Må derfor bruke "(" og ")" , (**gruppering**)
    - `/gupp(y|ies)/`

Regulære uttrykk

Kleene * operator:

- Vi vil fange repetisjoner av en instans, feks: Kolonne 1 Kolonne 2 Kolonne 3.

Regulære uttrykk

Kleene * operator:

- Vi vil fange repetisjoner av en instans, feks: Kolonne 1 Kolonne 2 Kolonne 3.
- Hva vil `/Kolonne␣[0-9]+␣*/` fange?

Regulære uttrykk

Kleene * operator:

- Vi vil fange repetisjoner av en instans, feks: Kolonne 1 Kolonne 2 Kolonne 3.
- Hva vil `/Kolonne␣[0-9]+␣*/` fange?
  - "Kolonne 1" etterfulgt av fritt antall mellomrom (feks. "Kolonne 1␣␣␣␣...")

Regulære uttrykk

Kleene * operator:

- Vi vil fange repetisjoner av en instans, feks: Kolonne 1 Kolonne 2 Kolonne 3.
- Hva vil `/Kolonne␣[0-9]+␣*/` fange?
  - "Kolonne 1" etterfulgt av fritt antall mellomrom (feks. "Kolonne 1␣␣␣␣...")
- Må bruke "`()`":
  - `/(Kolonne␣[0-9]+␣*)*/`
- Her har "`()`" presedens over "`*`"

Regulære uttrykk

Kleene * operator:

- Vi har `/[a-z]*/`
- Setningen “once upon a time”
- Hva vil `/[a-z]*/` fange?

Regulære uttrykk

Kleene * operator:

- Vi har `/[a-z]*/`
- Setningen “once upon a time”
- Hva vil `/[a-z]*/` fange?
  - ingenting? “o”? “on”? “onc”? “once”? “once␣”? “once␣u”? ...

Regulære uttrykk

Kleene * operator:

- Vi har `/[a-z]*/`
- Setningen “once upon a time”
- Hva vil `/[a-z]*/` fange?
  - ingenting? “o”? “on”? “onc”? “once”? “once␣”? “once␣u”? ...
  - “once”
- RU matcher alltid lengste strengen, de er kallt **greedy**

Regulære uttrykk

Presedens av RU operatorer:

1	Parentes	`()`
2	Tellere (counters)	`+ - ? {}`
3	Sekvenser og ankere	`the ^my end$`
4	Disjunksjon	`|`

Regulære uttrykk

- Nyttige forkortelser:

RU	=	Eksempel
\d	[0-9]	Lag␣av␣5
\D	[^0-9]	Blå␣himmel␣
\w	[A-Za-z0-9]	Dag
\W	[^A-Za-z0-9]	!!!!!
\s	[\r\t\n]	
\S	[^\s]	På␣Fløyen

Regulære uttrykk

- Nyttige forkortelser:

RU	Matcher
`*`	null eller flere
`+`	en eller flere
`?`	null eller en
`.`	wildcard, matcher hva som helst
`{n}`	*n* forekomster
`{n,m}`	fra *n* til *m* forekomster
`{n,}`	minst *n* forekomster

Regulære uttrykk

- Det som trenger "backslash":

RU	Eksempel
`\*`	I*N*1*1*4*0
`\.`	Dr. Nesehorn
`\?`	Dr. Nesehorn?
`\n`	ny linje
`\t`	tab

- Men også `/\[/`, og `/\\/` ...



Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Riktig dato?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Riktig dato?
- Hva er formatet?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Riktig dato?
- Hva er formatet?
  - siffer: 0-9
  - mellomrom: \s
  - ord (sekvens av bokstaver): [A-Za-z]
  - mellomrom: \s
  - tall: 1900-2099

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Riktig dato?
- Hva er formatet?
  - siffer: 0-9
  - mellomrom: \s
  - ord (sekvens av bokstaver): [A-Za-z]
  - mellomrom: \s
  - tall: 1900-2099

$$regex \rightarrow [0-9] + \backslash s[A-Za-z] + \backslash s((19|20)[1-9]+)$$

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Riktig dato?
- Hva er formatet?
  - siffer: 0-9
  - mellomrom: \s
  - ord (sekvens av bokstaver): [A-Za-z]
  - mellomrom: \s
  - tall: 1900-2099

$$regex \rightarrow [0-9] + \backslash s[A-Za-z] + \backslash s((19|20)[1-9]+)$$

Fanger den kun riktige strenger?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

$$regex \rightarrow [[0-9]+\s[A-Za-z]+\s((19|20)[1-9]+)$$

Fanger følgende:

- 6 januar 1992
- 3342 november 1988
- 9 fredag 1999
- 1 mars 2018

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

$$regex \rightarrow [[0-9]+\s[A-Za-z]+\s((19|20)[1-9]+)$$

Fanger følgende:

- 6 januar 1992
- 3342 november 1988
- 9 fredag 1999
- 1 mars 2018

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Hva er formatet?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Hva er formatet?
  - siffer: 0-9
  - mellomrom: \s
  - ord (sekvens av bokstaver): (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)
  - mellomrom: \s
  - tall: ((19|20)[0-9]+)

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Hva er formatet?
  - siffer: 0-9
  - mellomrom: \s
  - ord (sekvens av bokstaver): (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)
  - mellomrom: \s
  - tall: ((19|20)[0-9]+)

$$regex \rightarrow [[0-9]+\backslash s$$
$$(januar|februar|mars|april|mai|juni|juli|august|september|$$
$$oktober|november|desember)\backslash s\ ((19|20)[0-9]+)$$

Fanger den kun riktige strenger?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

$$regex \rightarrow [[0-9]+\backslash s (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)\backslash s ((19|20)[0-9]+)$$

Den fanger:

- 6 januar 1992
- 25 juni 2005
- 3342 november 1988
- 1 mars 2018
- 30 juli 190221

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

$$regex \rightarrow [[0-9]+\backslash s (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)\backslash s ((19|20)[0-9]+)$$

Den fanger:

- 6 januar 1992
- 25 juni 2005
- 3342 november 1988
- 1 mars 2018
- 30 juli 190221

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Hva er formatet?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Hva er formatet?
  - siffer: 1-9, 1 etterfulgt av 0-9, 2 etterfulgt av 0-9, 3 etterfulgt av 0 eller 1
  - mellomrom: \s
  - ord (sekvens av bokstaver): (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)
  - mellomrom: \s
  - tall: (19|20) etterfulgt av maks to siffer 0-9

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

- Hva er formatet?
  - siffer: 1-9, 1 etterfulgt av 0-9, 2 etterfulgt av 0-9, 3 etterfulgt av 0 eller 1
  - mellomrom: \s
  - ord (sekvens av bokstaver): (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)
  - mellomrom: \s
  - tall: (19|20) etterfulgt av maks to siffer 0-9

$$regex \rightarrow [([1-9]|[12][0-9]|3[01])\backslash s (januar|februar|mars|april|mai|juni|juli|august|september|oktober|november|desember)\backslash s ((19|20)\backslash d\{2\})$$

Fanger den kun riktige strenger?

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

Eksempel 1

liste = ['6 januar 1992', '25 juni 2005', '3342 november 1988', '9 fredag 1999', '1 mars 2018', '30 juli 190221']

$$regex \rightarrow [([1-9]|[12][0-9]|3[01])\backslash s \\ (januar|februar|mars|april|mai|juni|juli|august|september| \\ oktober|november|desember)\backslash s\ ((19|20)\backslash d\{2\})$$

Den fanger:

- 6 januar 1992
- 25 juni 2005
- 1 mars 2018

Regulære uttrykk

- **Et eksempel: Finne alle forekomster av *og* i en tekst**
  - /og/
    - Problem: *Og det ble kveld, og det ble morgen . . .*

Regulære uttrykk

- **Et eksempel: Finne alle forekomster av *og* i en tekst**
  - `/og/`
    - Problem: *Og det ble kveld, og det ble morgen . . .*
  - `/[Oo]g/`
    - Problem: *Togets rutetider*

Regulære uttrykk

- **Et eksempel: Finne alle forekomster av *og* i en tekst**
  - `/og/`
    - Problem: *Og det ble kveld, og det ble morgen . . .*
  - `/[Oo]g/`
    - Problem: *Togets rutetider*
  - `/\s[Oo]g\s/`

Regulære uttrykk

- **Et eksempel: Finne alle forekomster av *og* i en tekst**
  - `/og/`
    - Problem: *Og det ble kveld, og det ble morgen . . .*
  - `/[Oo]g/`
    - Problem: *Togets rutetider*
  - `/\s[Oo]g\s/` eller `/\b[Oo]g\b/`
- Minimere antall falske positiver (uriktig matchet, feks *Toget*) og falske negativer (uriktig utelukket, feks *Og*)

Regulære uttrykk - sub

- Substitusjon (perl format):
  - `s/color/colour/`
  - `s/versjon\s2\.4/versjon\s2\.5/`

Regulære uttrykk - sub

- Substitusjon (perl format):
  - `s/color/colour/`
  - `s/versjon\s2\.4/versjon\s2\.5/`
- Substitusjon (python format):
  - re.sub(“color”, “colour”, text)
  - re.sub(“versjon 2.4”, “versjon 2.5”, text)

Regulære uttrykk

- ELIZA (Weizenbaum 1966):

User:	*Men are all alike*
ELIZA:	IN WHAT WAY?
User:	*They're always bugging us about something*
ELIZA:	CAN YOU THINK OF AN EXAMPLE?
User:	*Well, my boyfriend made me come here*
ELIZA:	YOUR BOYFRIEND MADE YOU COME HERE.
User:	*He says I am depressed much of the time*
ELIZA:	I'M SORRY TO HEAR THAT YOU ARE DEPRESSED.

Regulære uttrykk

- ELIZA (Weizenbaum 1966):

User:	*Men are all alike*
ELIZA:	IN WHAT WAY?
User:	*They're always bugging us about something*
ELIZA:	CAN YOU THINK OF AN EXAMPLE?
User:	*Well, my boyfriend made me come here*
ELIZA:	YOUR BOYFRIEND MADE YOU COME HERE.
User:	*He says I am depressed much of the time*
ELIZA:	I'M SORRY TO HEAR THAT YOU ARE DEPRESSED.

```
s/.* I am (depressed|sad) .*
/ I am sorry to hear that you are \1/
s/.* (all|always) .*
/ Can you think of an example /
```

Prøv hjemme med og uten Python

- Beskriv strengene som aksepteres av følgende regulære uttrykk
  - `/ab+a/`
  - `/(ab)*/`
  - `/([^aeiou][aeiou])/`
  - `/\sdis[a-z]+\s/`