# IN1140: Introduksjon til språkteknologi

## *Forelesning #12*

Lilja Øvrelid

Universitetet i Oslo

18 november 2024



# Tema for i dag

## I dag

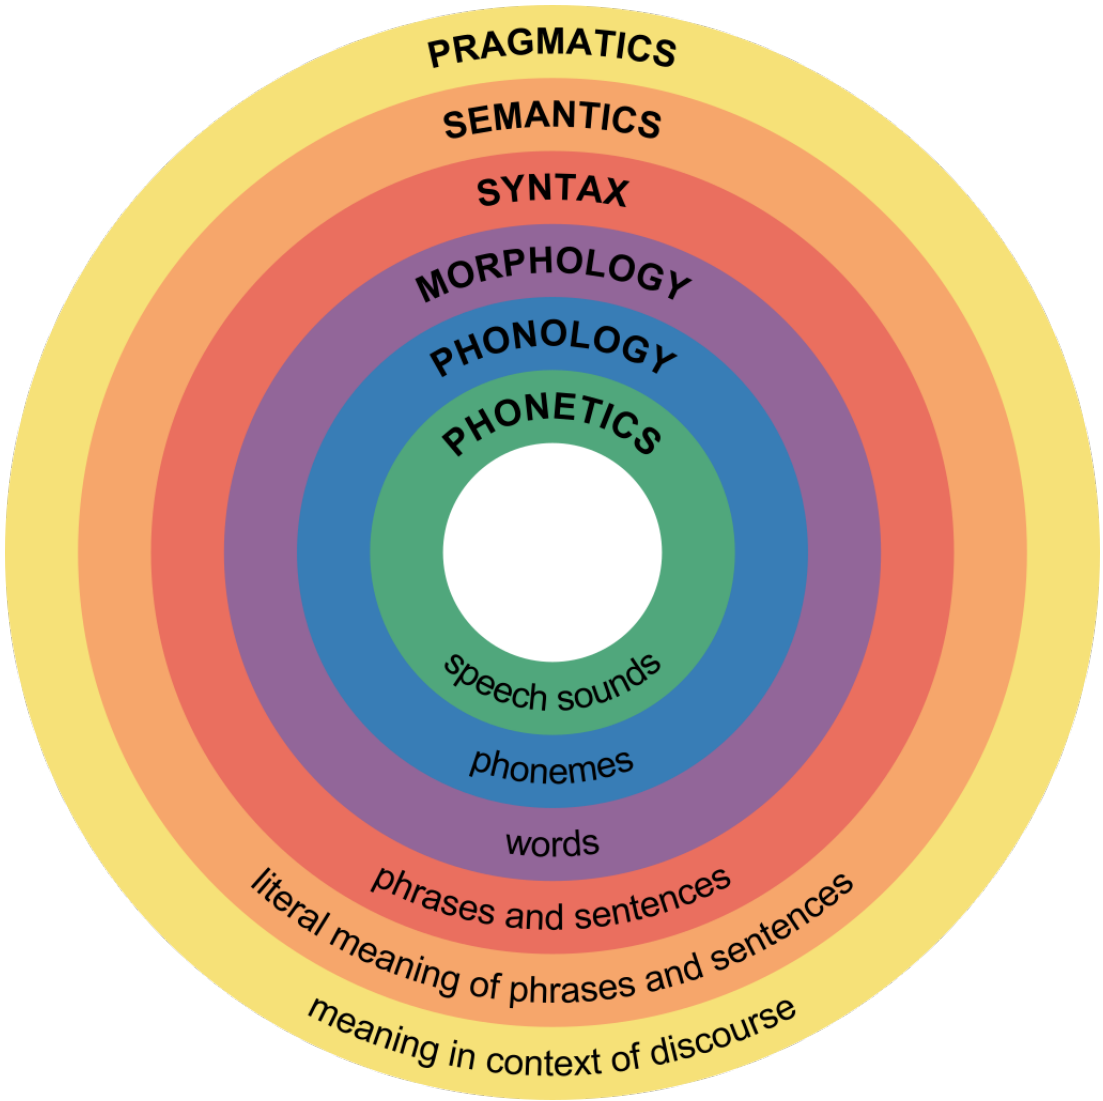
- Repetisjon
- Eksamensforberedelser

# Fra emnebeskrivelsen

*Emnet gir en innføring i språkteknologi: metoder for automatisk analyse av språklige data. Det vil videre gi en innføring i lingvistisk teori og relatere denne til språkteknologiske problemområder. Det vil gis et første møte med noen språkteknologiske oppgaver som eksempelvis tokenisering, n-grammodeller, tagging og klassifisering.*

# Lingvistikk

# Lingvistikk



# Lingvistikk

- Vitenskapelige studiet av språk
- Vitenskapelig? Systematisk studie av regler, systemer og prinsipper i menneskelige språk
- Kunnskap om enheter og regler i et språk

## Nivåer

- Fonologi: lyder $\Rightarrow$ ord
- Morfologi: morfemer $\Rightarrow$ ord
- Syntaks: ord $\Rightarrow$ fraser, fraser $\Rightarrow$ setninger
- Semantikk: ord $\Rightarrow$ mening, setninger $\Rightarrow$ mening

# Flertydighet

- De fleste språkteknologiske applikasjoner må håndtere flertydighet ("ambiguity")
- Kjennetegner naturlige språk, på alle nivåer
  - *I saw her duck*
  - *Krasjet med rådyr på moped* (Agderposten)

# Flertydighet

- De fleste språkteknologiske applikasjoner må håndtere flertydighet ("ambiguity")
- Kjennetegner naturlige språk, på alle nivåer
  - *I saw her duck*
  - *Krasjet med rådyr på moped* (Agderposten)
- Språklige data:
  - **korpusdata** helt sentralt (representativitet)

# Morfologi




Handler om **ord**

- Hvordan ord er bygd opp (morfemer)
- Hvordan nye ord dannes (avledning, sammensetning)
- Hvordan ord bøyes

# Morfologi

- Morfemet er den elementære (minste) lingvistiske enheten
- To hovedtyper:
  - Frie morfemer: ord. *boy*, *desire*, *gentle*, *man*
  - Bundne morfemer: affikser.
    - prefikser: *un-*, *pre-*, *bi-*
    - suffikser: *-ing*, *-ish*, *-ness*

# Avledning

- En avledning er et ord som er dannet fra et annet ord ved hjelp av et avledningsaffiks (prefiks eller suffiks),
- Avledningsaffiksene har ofte et klart semantisk innhold

- *u-* - negasjon: *umulig, uvel, urolig*
- *for-* - foran: *forelese, forbokstav, formann*
- *-er* - den som utfører handlingen: *fisker, baker*

# Bøyning

- Markerer kategorier som tid (tempus), tall (numerus), bestemthet, etc.
- Noen eksempler:

- **Tid (tempus)**: angir tidspunktet for handlingen. Presens (nåtid) og preteritum (fortid) *liker-likte, likes-liked*
- **Tall**: entall og flertall *bil-biler, car-cars*
- **Bestemthet**: uttrykkes i hovedsak ved suffiks (*bilen, huset*)

# Ordklasser?

- Bindeledd mellom ordet og setningen (syntaks):
  - Sier noe om hva slags kontekster et ord forekommer i
  - Sier noe om uttale (*record*, *content*)
- Viktig i en rekke språkteknologiske oppgaver:
  - Talesyntese
  - "Chunking", syntaktisk parsing
  - Informasjonsekstraksjon
- Vi trenger kriterier for ordklasseinndeling

# Ordklassekriterier

## Tre slags kriterier:

1. Formelle (morfologiske) kriterier
   - hvilke bøyningsformer har ordet?
     - *hare* - *haren* og *redd* - *reddere*
2. Funksjonelle (syntaktiske) kriterier
   - hvordan kan ordet kombineres med andre ord?
     - *en redd hare* og *redd for ilden*
3. Betydningsmessige (semantiske) kriterier
   - hva er typiske betydninger hos ord i ordklassen?
     - *hare* - dyr, levende vesen
     - *redd* - egenskap

# Inndeling av ordklasser

## åpne vs. lukkede ordklasser

- nye medlemmer?
- åpne: substantiv, verb og adjektiv inneholder mange tusen ord, kan enkelt fylle på med nye
- lukkede: inneholder mange færre ord enn de åpne kan ikke fritt skape nye ord gjennom orddannelse

# Inndeling av ordklasser

## åpne vs. lukkede ordklasser

- nye medlemmer?
- åpne: substantiv, verb og adjektiv inneholder mange tusen ord, kan enkelt fylle på med nye
- lukkede: inneholder mange færre ord enn de åpne kan ikke fritt skape nye ord gjennom orddannelse

## innholdsord vs. funksjonsord

- semantisk innhold?
- innholdsord: substantiv, verb, adjektiv rikt betydningsinnhold, refererer utenfor språket
- funksjonsord: mer allment betydningsinnhold, refererer ikke utenfor språket. Finnes fremst i de lukkede ordklassene.

# Syntaks

"Studiet av hvordan setninger bygges opp av ord og ordkombinasjoner"



# Konstituenter

- Konstituenter – grupperinger av ord i en setning, fungerer som en enhet

**Lingvistiske tester:**

- "stå alene"-testen
- "erstattes med pronomen"
- "Flyttes som enhet"

- Norsk eksempel: *Den lille hunden lekte i hagen*

# Konstituenter

- Konstituenter – grupperinger av ord i en setning, fungerer som en enhet

**Lingvistiske tester:**

- "stå alene"-testen
- "erstattes med pronomen"
- "Flyttes som enhet"

- Norsk eksempel: *Den lille hunden lekte i hagen*
  - *(Hvor lekte den lille hunden?) I hagen* (stå alene)
  - *Den lille hunden lekte* **der** (erstattes med pronomen)
  - *I hagen lekte den lille hunden* (flytter som enhet)

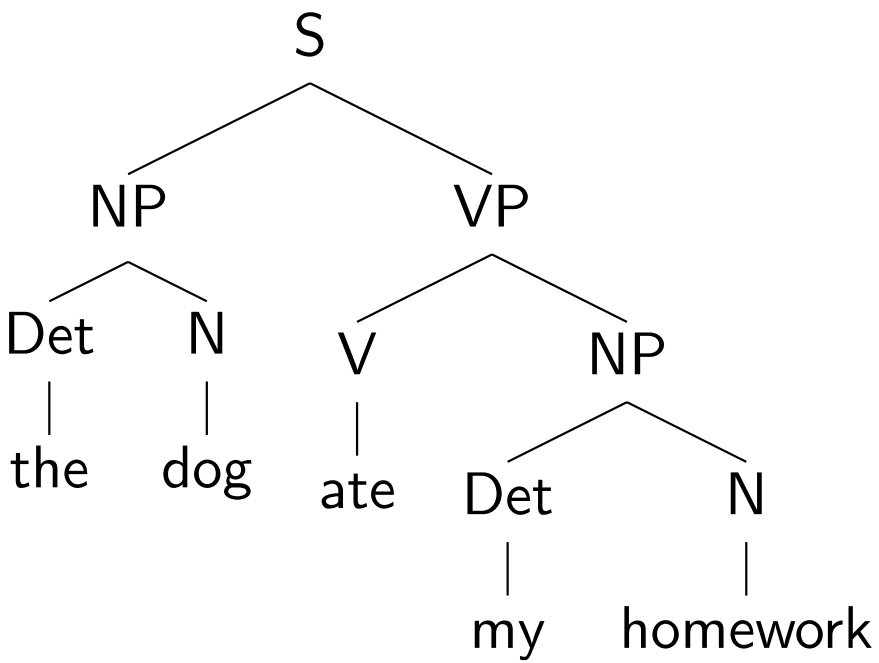
# Syntaks

- Fraser - bygger opp setningen eller andre fraser og navngis etter hodet
  - NP (noun phrase), f.eks. *det pene huset*
  - VP (verb phrase) f.eks. *liker fotball*
  - PP (prepositional phrase), f.eks. *i skogen*

  etc.

# Syntaktiske kategorier

- Frasale kategorier: NP, VP, AdjP, PP
- Leksikale kategorier (ordklasser): N, V, P, Adj, Adv
- Frasestrukturtre (Phrase Structure (PS) tree)



# Flertydighet

- Flere mulige grupperinger av ord
- Flere mulige syntaktisk analyser
- Ulik analyse gir ulik betydning

- *Gamle menn og kvinner kan forlate skipet*

# Flertydighet

- Flere mulige grupperinger av ord
- Flere mulige syntaktisk analyser
- Ulik analyse gir ulik betydning

- *Gamle menn og kvinner kan forlate skipet*
- [*Gamle menn*] *og* [*kvinner*]
- [*Gamle* [*menn og kvinner*]]

# Flertydighet

- Flere mulige grupperinger av ord
- Flere mulige syntaktisk analyser
- Ulik analyse gir ulik betydning

- *Gamle menn og kvinner kan forlate skipet*
- [*Gamle menn*] *og* [*kvinner*]
- [*Gamle* [*menn og kvinner*]]

- *Mannen så gutten med kikkerten*

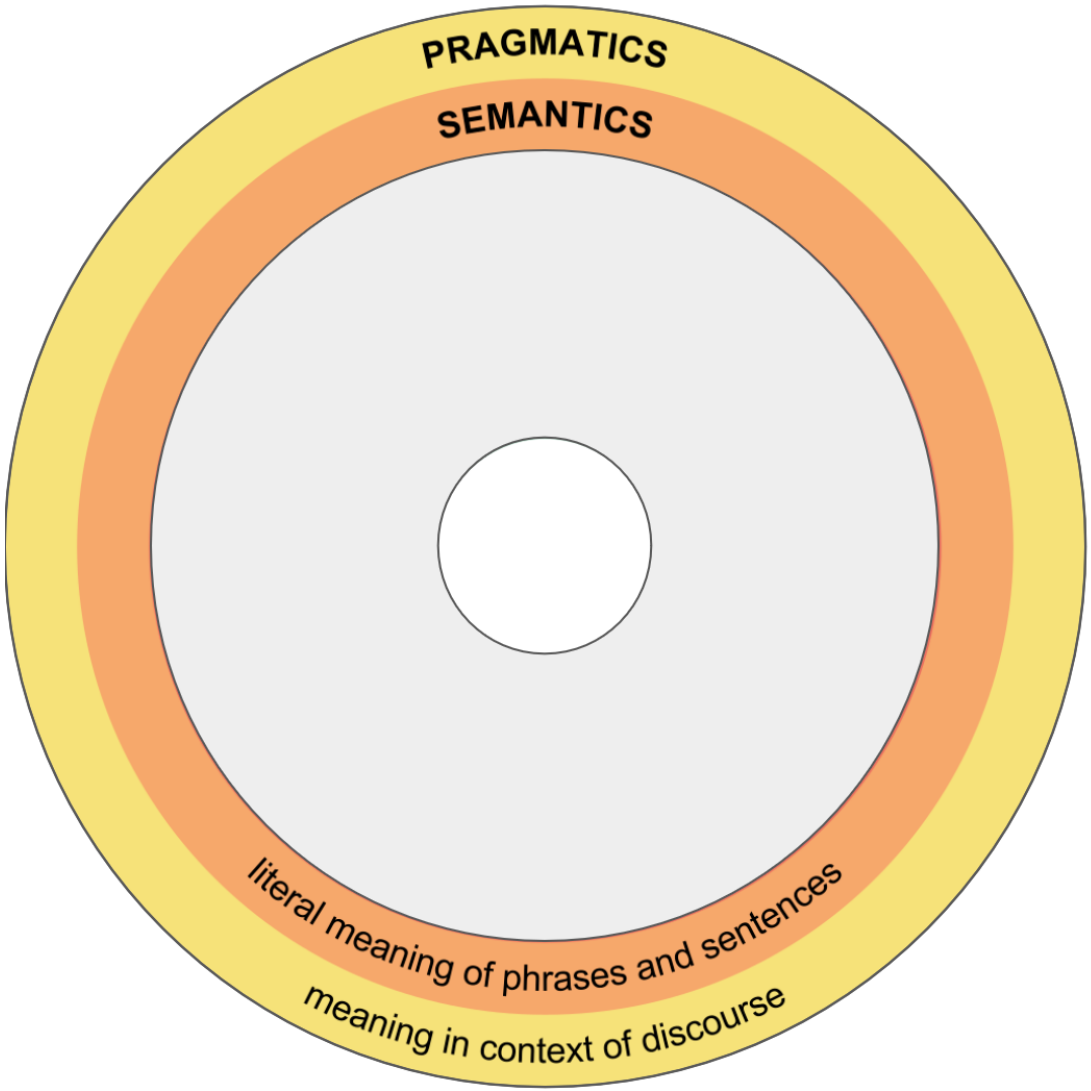
# Flertydighet

- Flere mulige grupperinger av ord
- Flere mulige syntaktisk analyser
- Ulik analyse gir ulik betydning

- *Gamle menn og kvinner kan forlate skipet*
- [*Gamle menn*] *og* [*kvinner*]
- [*Gamle* [*menn og kvinner*]]

- *Mannen så gutten med kikkerten*
- [*så gutten*] [*med kikkerten*]
- [*så* [*gutten med kikkerten*]]

# Semantikk




- Studiet av betydning slik det uttrykkes gjennom språk
- Betydning til morfemer, ord, fraser og setninger
  - Leksikal semantikk
  - Setningssemantikk
  - (Pragmatikk: hvordan konteksten påvirker betydning)

# Leksikal semantikk

- Representerer betydningen til ord
- Vise hvordan betydningene er relatert

## Leksikale relasjoner:

- Homonymi (not, knot) og polysemi (flere betydninger, men betydningene er relatert)
- Synonymi
- Antonymi (enkle, gradérbare, taksonomiske søstre ...)
- Hyponymi (hund, katt er hyponymer av dyr)

# Setningssemantikk: formell semantikk

- Beregner **sannhetsverdien** for setninger basert på betydningen til mindre deler (ord, fraser)
- Semantisk analyse ved oversettelse fra engelsk (eller norsk eller . . . ) til et universelt metaspråk (førsteordenslogikk)

# Setningssemantikk: semantiske roller

- Semantiske roller beskriver den semantiske relasjonen som argumenter har til handlingen beskrevet av verbet
- *Nina hevet bilen med jekken*
  - Nina – deltageren som er ansvarlig for å utføre handlingen beskrevet av verbet
  - bilen – blir påvirket av handlingen
  - jekken – middelet som Nina bruker til å utføre handlingen

# Setningssemantikk: semantiske roller

- Semantiske roller beskriver den semantiske relasjonen som argumenter har til handlingen beskrevet av verbet
- *Nina hevet bilen med jekken*
  - Nina – deltageren som er ansvarlig for å utføre handlingen beskrevet av verbet
  - bilen – blir påvirket av handlingen
  - jekken – middelet som Nina bruker til å utføre handlingen

| *Nina* | *hevet* | *bilen* | *med* | *jekken* |
|---|---|---|---|---|
| AGENT | | THEME | | INSTRUMENT |

# Formelle modeller

# Formelle modeller

- Hentet fra matematikk, statistikk og (generell) informatikk
- Representere lingvistisk kunnskap
  - Regulære uttrykk
  - Formelle regelsystemer
  - Statistiske modeller

# Regulære uttrykk

- Et regulært uttrykk er en beskrivelse av en mengde strenger
- Brukes til tekstsøk

## Regulære uttrykk består av

- Strenger bestående av tegn: `b`, `INF1820`, `informatikk`
- Disjunksjon: `penge(r|ne)`, `[Dd]en`, `[A-Z]`, `[0-9]`
- Negasjon: `[^b]` `[^A-Z0-9]`
- Tellere: Kleenes `*`, `+`, `?`
  - opsjonalitet (0 eller 1): `?` `woodchucks?`
  - hvilket som helst antall (0 eller flere): Kleenes `*` `baaa*!` `[0-9][0-9]*`
  - minst en: `+`: `baa+!` `[0-9]+` `kroner`
- "wildcard" for et hvilket som helst tegn: `.`

  `beg.n` `beltedyr.*beltedyr`

# Kontekstfrie grammatikker (CFGer)

- Formell modell som fanger inn syntaktisk konstituentstatus og rekkefølge
- Formelt: en CFG er en 4-tuppel $< N, \Sigma, P, S >$, der
  - $N$ er en mengde ikke-terminale symboler (syntaktiske kategorier)
  - $\Sigma$ er en mengde terminale symboler (ord)
  - $R$ er en mengde regler (produksjoner) på formen $A \rightarrow \alpha$, der
    - A er en ikke-terminal
    - $\alpha$ er en streng av symboler hentet fra mengden $(\Sigma \cup N)*$, dvs både terminaler og ikke-terminaler
    - Et særskilt startsymbol $S$

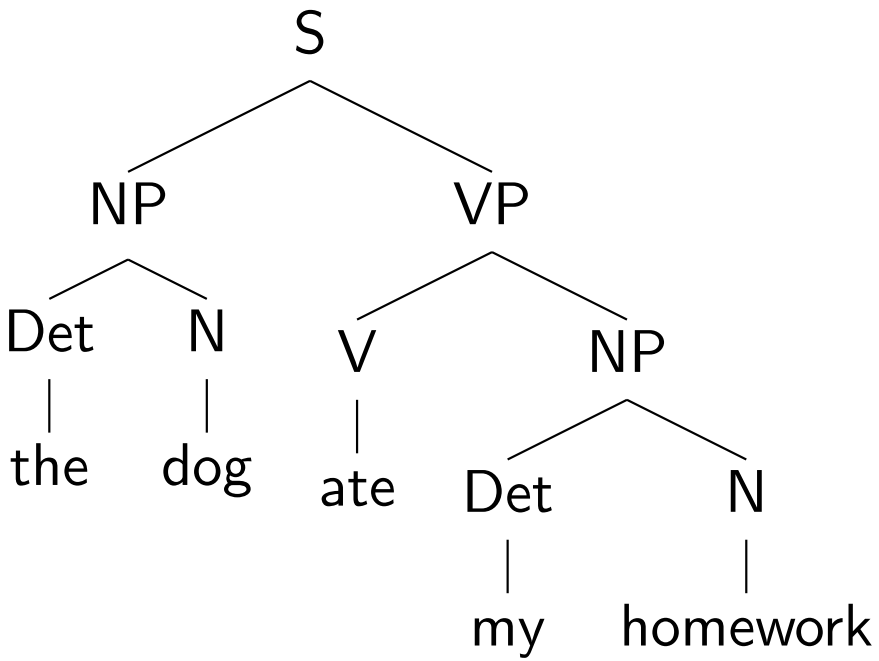
# Kontekstfrie grammatikker (CFGer)

Eksempel CFG

- La $G =< N, \Sigma, R, S >$ der
  - $N = \{$S, NP, VP , DT, N, V, N$\}$
  - $\Sigma = \{$*the, my, dog, homework, ate*$\}$
  - $R = \{$S $\rightarrow$ NP VP,
    NP $\rightarrow$ DT N,
    VP $\rightarrow$ V NP,
    DT $\rightarrow$ *the, my*,
    N $\rightarrow$ *dog, homework*,
    V $\rightarrow$ *ate*,
    $\}$
  - $S =$S

# Trær

- En rekke applikasjoner av reglene kan visualiseres som trær



# Rekursive stukturer

| Direkte rekursjon: | |
|---|---|
| NP $\rightarrow$ NP PP | |
| VP $\rightarrow$ VP PP | |

| Indirekte rekursjon: | |
|---|---|
| S $\rightarrow$ NP VP | |
| VP $\rightarrow$ V CP | |
| CP $\rightarrow$ C S | *said that the flight was late* |

# Sannsynlighet

- Lar oss kvantifisere usikkerhet.
- Uttrykk for sjanse eller odds.
- Sannsynlighet for en hendelse: en verdi mellom 0 og 1, gitt ved $P$:
  - $P$(seks på terningen)
  - Betinget sannsynlighet:
    $P$(sol i morgen | regn i dag)



# Sannsynlighet

- Felles sannsynlighet ("joint probability")
  - $P(A, B)$: sannsynligheten for at både $A$ *og* $B$ skjer.
  - Skrives også: $P(A \cap B)$.
- Betinget sannsynlighet ("conditional probability")
  - Vi har ofte *delvis kunnskap* om en hendelse: $P(A|B)$

# Språkmodeller

- En språkmodell tilskriver sannsynligheter $P(x)$ til alle ordsekvenser $x$ i et språk $L$.
- Gitt en sekvens $w_1, w_2 \ldots w_k = w_1^k$ så ønsker vi å estimere den felles sannsynligheten for ordene $P(w_1^k)$.
- F.eks: $P(\text{jeg}, \text{vil}, \text{drikke}, \text{kaffe}, \text{nå})$

# Språkmodeller

- En språkmodell tilskriver sannsynligheter $P(x)$ til alle ordsekvenser $x$ i et språk $L$.
- Gitt en sekvens $w_1, w_2 \ldots w_k = w_1^k$ så ønsker vi å estimere den felles sannsynligheten for ordene $P(w_1^k)$.
- F.eks: $P(\text{jeg}, \text{vil}, \text{drikke}, \text{kaffe}, \text{nå})$

1. Vi bruker produktsetningen:

   $$P(w_1 \ldots w_k) = P(w_1)\, P(w_2|w_1)\, P(w_3|w_1, w_2) \ldots P(w_k|w_1^{k-1})$$

2. Vi forenkler med Markovantagelsen:

   De $n-1$ siste elementene lar oss tilnærme effekten av å betrakte hele sekvensen.

   Eksempel for $n = 2$:

   $$P\left(w_1^k\right) \approx \prod_{i=1}^{k} P\left(w_i|w_{i-1}\right)$$

# $n$-grammer

- Et $n$-gram er en delsekvens på $n$ ord:
- $n$-grammer i *jeg vil drikke kaffe nå*:

- unigrammer ($n = 1$): $\langle$*jeg*$\rangle$, $\langle$*vil*$\rangle$, $\langle$*drikke*$\rangle$, $\langle$*kaffe*$\rangle$, $\langle$*nå*$\rangle$
- bigrammer ($n = 2$): $\langle$*jeg, vil*$\rangle$, $\langle$*vil, drikke*$\rangle$, $\langle$*drikke, kaffe*$\rangle$ $\langle$*kaffe, nå*$\rangle$
- trigrammer ($n = 3$): $\langle$*jeg, vil, drikke*$\rangle$, $\langle$*vil, drikke, kaffe*$\rangle$, $\langle$*drikke, kaffe, nå*$\rangle$
- 4-grammer ($n = 4$): $\langle$*jeg, vil, drikke, kaffe*$\rangle$, $\langle$*vil, drikke, kaffe, nå*$\rangle$

# Å trene en $n$-grammodell: MLE

- Vi estimerer $P$ ved å telle $n$-grammer og se på relativ frekvens:

$$P\left(w_i|w_{i-n+1},\ldots,w_{i-1}\right) = \frac{Count\left(w_{i-n+1},\ldots,w_i\right)}{Count(w_{i-n+1},\ldots,w_{i-1})}$$

# Å trene en $n$-grammodell: MLE

- Vi estimerer $P$ ved å telle $n$-grammer og se på relativ frekvens:

$$P\left(w_i|w_{i-n+1},\ldots,w_{i-1}\right) = \frac{Count\left(w_{i-n+1},\ldots,w_i\right)}{Count(w_{i-n+1},\ldots,w_{i-1})}$$

- F.eks, for bigrammer:

$$P\left(\text{kaffe}|\text{drikke}\right) = \frac{Count\left(\text{drikke, kaffe}\right)}{Count\left(\text{drikke}\right)}$$

# Å trene en $n$-grammodell: MLE

- Vi estimerer $P$ ved å telle $n$-grammer og se på relativ frekvens:

$$P\left(w_i|w_{i-n+1},\ldots,w_{i-1}\right) = \frac{Count\left(w_{i-n+1},\ldots,w_i\right)}{Count(w_{i-n+1},\ldots,w_{i-1})}$$

- F.eks, for bigrammer:

$$P\left(\text{kaffe}|\text{drikke}\right) = \frac{Count\left(\text{drikke, kaffe}\right)}{Count\left(\text{drikke}\right)}$$

- Kalles Maximum Likelihood Estimation (MLE).
- I praksis legger vi gjerne også til markører for start og slutt for sekvensen: <s> og </s>.

# Bayes regel

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

- Bayes regel/teorem viser hvordan vi kan beregne inverse sannsynligheter, dvs dersom vi vet $P(A|B)$, hvordan kan vi beregne $P(B|A)$?
- Brukes i Naive Bayes klassifisering, gjør enklere å estimere sannsynligheter fra et korpus

# Statistisk klassifisering

- Sentral metode innenfor maskinlæring
- Automatisk avgjøre hvilken kategori en observasjon tilhører
- Basert på treningsdata: observasjoner der kategorien er kjent
  - e-post $\rightarrow$ {spam, ikke-spam}
  - dokument $\rightarrow$ {positiv, negativ}
  - ord $\rightarrow$ {betydning$_1$, betydning$_2$}
- veiledet ('supervised') klassifisering: klassifisering som benytter treningsdata
- Evaluerer på usette testdata

# Naive Bayes-klassifisering

- En enkel men effektiv statistisk klassifiserer

$$\hat{c} = \underset{c \in C}{\operatorname{argmax}} P(c) \prod_{j=1}^{n} P(f_j|c)$$

# Naive Bayes-klassifisering

- En enkel men effektiv statistisk klassifiserer

$$\hat{c} = \underset{c \in C}{\operatorname{argmax}} P(c) \prod_{j=1}^{n} P(f_j|c)$$

- Vi **trener** klassifisereren ved å beregne sannsynligheter fra et korpus (MLE)

**2 sannsynligheter:**

1. prior-sannsynligheten for klassen $P(c)$
2. sannsynligheten for individuelle trekk $P(f_j|c)$

# Språkteknologiske Oppgaver & Applikasjoner

# Tokenisering

- Dele opp en tekst i løpende ord
- Første skritt i nesten alle språkteknologiske oppgaver

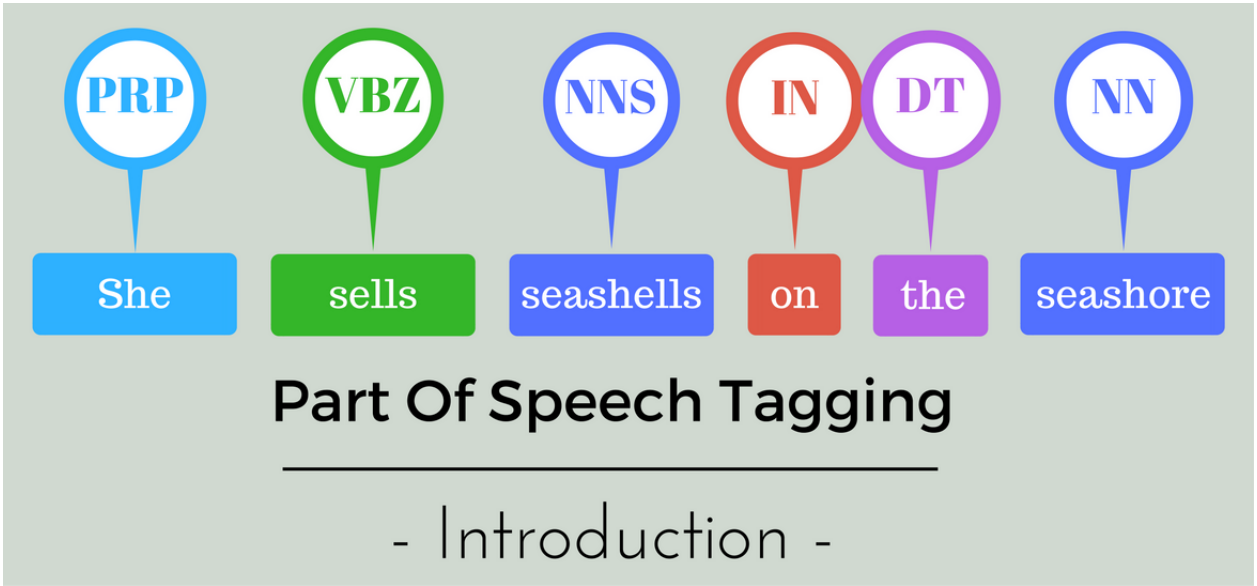
**Problematiske tilfeller:**

- Forkortelser: *f.eks.*
- Bindestrek: *Oslo-borgeren*
- Mellomrom: *New York*
- URL'er
- ...

- Tokens og typer

# Ordklassetagging

- Input: streng av ord og en spesifisert mengde tagger (taggsett)
- Output: en tagg per ord

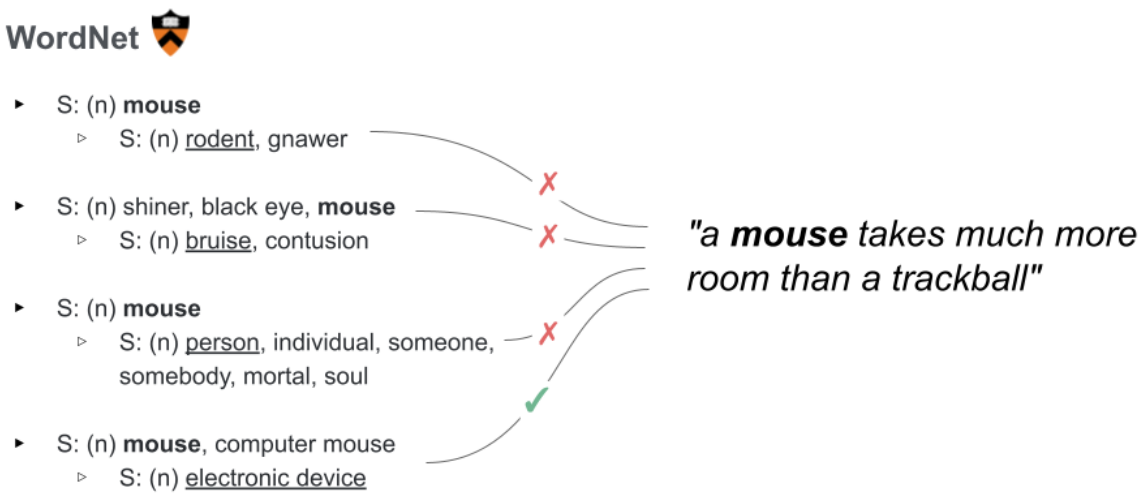



- **Flertydighet**
- Ekstrinsisk og intrinsisk evaluering

- Chunking:
  - Dele setningen inn i en sekvens **"chunks"**
  - En chunk inneholder et **hode**, muligens med noen funksjonsord/modifikatorer først
    [walk] [straight past] [the lake]
- Forenklede konstituenter ("fram til hodet")
- Ikke komplett syntaktisk beskrivelse, men tilstrekkelig for mange applikasjoner
- Ikke-rekursive: en chunk kan ikke inneholde en chunk av samme kategori

# Betydningsdisambiguering

- Word Sense Disambiguation (WSD) – akivt felt innenfor språkteknologi
  - gitt en setning med et spesifikt målord ("target word") og en liste med betydninger (f.eks. fra WordNet)
  - angi korrekt betydning for målordet i den setningen
- Klassifisering basert på et annotert datasett
- Naive Bayes-klassifisering



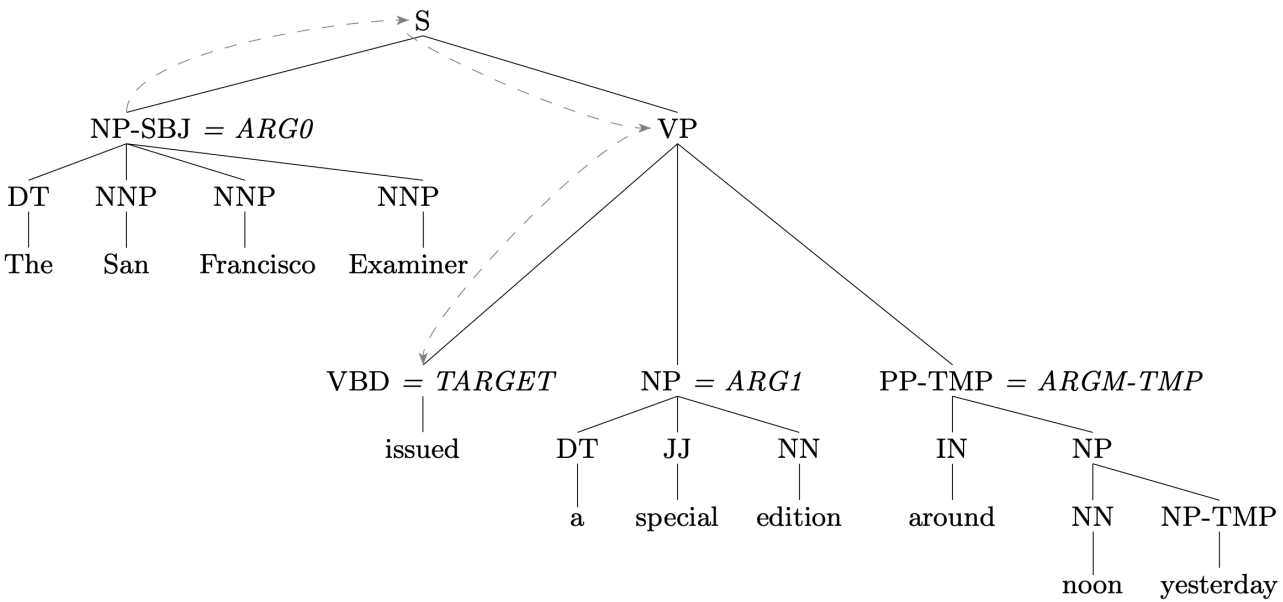
# Named Entity Recognition (NER)

- Automatisk **gjenkjenning** og **kategorisering** av egennavn
- Vanlige kategorier: person, organisasjon, sted (lokasjon), geo-politisk entitet

| | ORG | | | | | GPE_LOC | |
|---|---|---|---|---|---|---|---|
| Den | internasjonale | domstolen | har | sete | i | Haag | . |
| *The* | *International* | *Court of Justice* | *has* | *its seat* | *in* | *The Hague* | *.* |

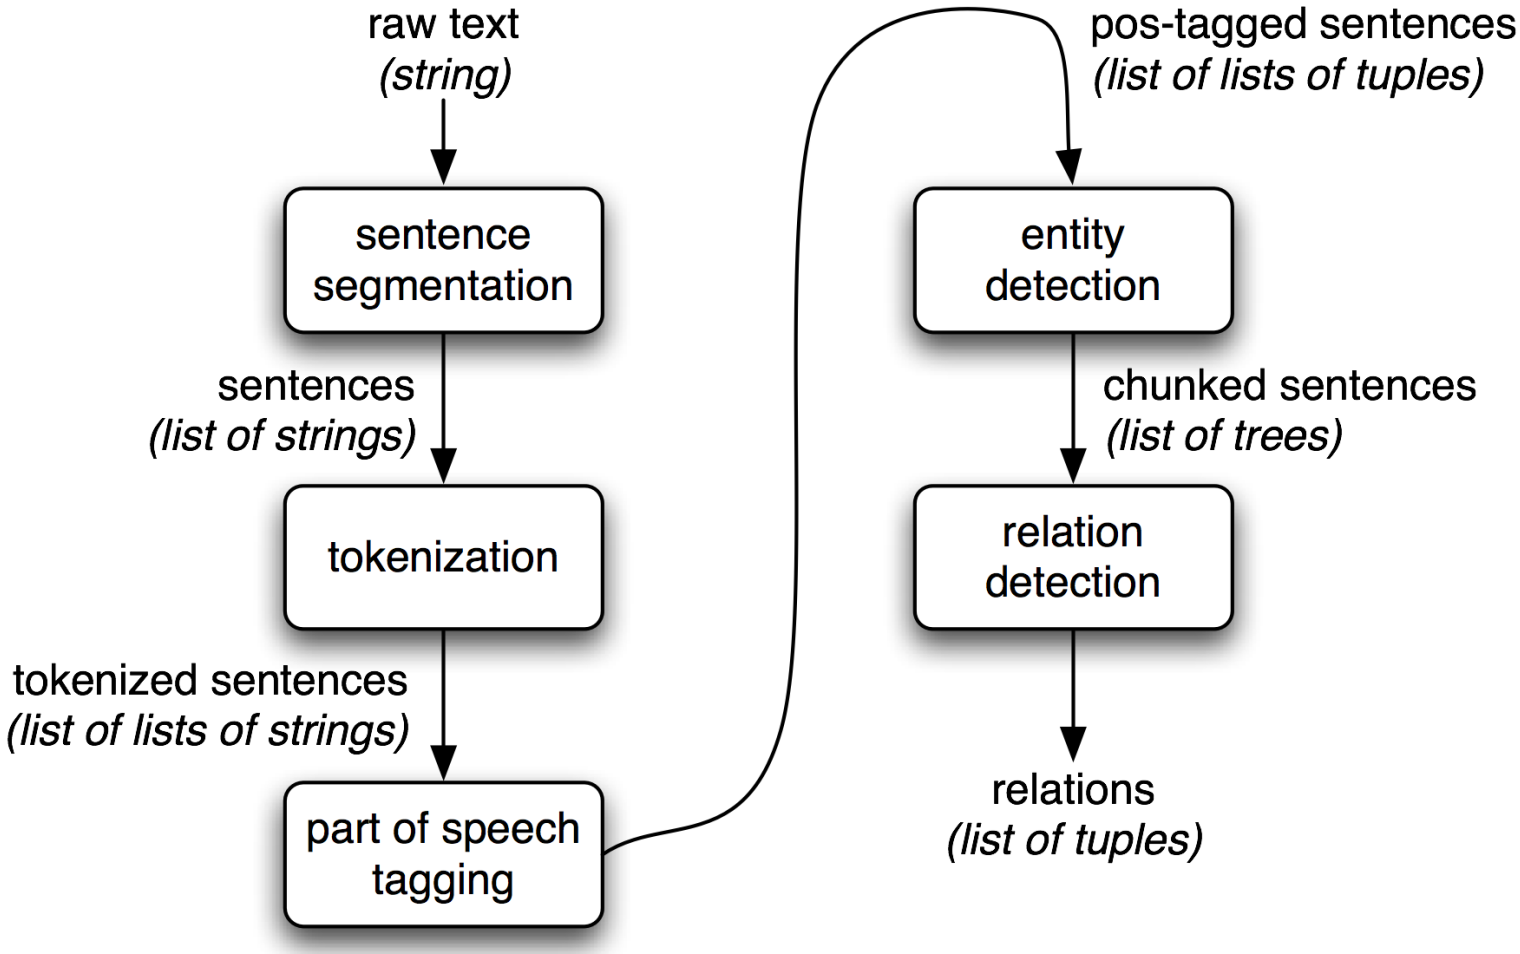
# SRL

- Oppgaven: finne semantiske roller for hvert argument i setninger
- Hvorfor?
  - felles semantisk representasjon for setninger
  - forbedrer en rekke NLP-applikasjoner: spørsmål-svar (QA), maskinoversettelse
- Klassifiserer noder (konstituenter) i det syntaktiske treet
- Trekk hentet fra ordformer, ordklasser og syntaktisk tre



# Informasjonsekstraksjon (IE)

Kombinerer mange språkteknologiske moduler:



# Sentimentanalyse




https://www.clickworker.de/wp-content/uploads/2017/02/Sentiment-Analyse.jpg

- På dokument/setningsnivå
- Klassifisering (f.eks. Naive Bayes)
- Leksikon (manuelt/automatisk)

# Question Answering

- De fleste Question-Answering (QA) systemer fokuserer på fakta-baserte spørsmål, spørsmål som kan besvares med enkle fakta uttrykt i korte tekster.

- Svarene på spørsmålene nedenfor kan uttrykkes med navn, tidsuttrykk, eller sted:
  1. Hvem grunnla Virgin Airlines?
  2. Hva er gjennomsnittsalderen i Real Madrid?
  3. Hvor holder SAS til?

- Skiller mellom IR-baserte og kunnskapsbaserte metoder


That's all Folks!

# Eksamensforberedelser

- Eksamen: 28 november kl 15:00 i Silurveien

# Eksamensforberedelser

- Eksamen: 28 november kl 15:00 i Silurveien
- Tenk eksamen
  - pensum: les **og** jobb aktivt med stoffet
  - gruppeoppgaver, teoretiske oblig-oppgaver, tidligere eksamensoppgaver
  - få hjelp: gruppetimer, medstudenter, digitalt
- Hva funker for deg? (Skrive, snakke og/eller lytte? Gjerne en kombinasjon)
- Ta prøveeksamen (Inspera)
- Gjennomgang: eksamensverksted 20 november kl 16 (påmelding, se beskjed på emnesiden)

# Obligkonkurransen

Vinner(e) annonseres på eksamensverksted!