

IN1140: Introduksjon til språkteknologi

Forelesning #1

Lilja Øvrelid

Universitetet i Oslo

22. august 2019



- ▶ Introduksjon
- ▶ Hva er språkteknologi?
- ▶ Hva er IN1140?
- ▶ Praktiske detaljer
 - ▶ Grupper
 - ▶ Obliger
 - ▶ Lærebøker
 - ▶ Kontakt
 - ▶ m.m.



Screencasting



- ▶ Tar opp **screencast** for hver forelesning (lyd + foiler).
- ▶ Egen **YouTube-kanal**:
<https://www.youtube.com/channel/UCE1IhV-Q-PuAkg2Fb350MIQ>
- ▶ Ment som et supplement, for repetisjon.



Forelesere

- ▶ Samia Touileb (samiat@ifi.uio.no)
- ▶ Lilja Øvrelid (liljao)
- ▶ Fra språkteknologigruppa (LTG)

Gruppelærere

- ▶ Tania-Adelina Bulz (taniaadb)
- ▶ Annika Willoch Olstad (annikaol)

Tid & sted

- ▶ Gruppe 1: man. 10:15–12:00, Datastue Limbo.
- ▶ Gruppe 2: ons. 08:15–10:00, Datastue Limbo.
- ▶ Forelesninger: tors. 12:15–14:00 i **Caml** (Ole-Johan Dahls hus / IFI).
- ▶ **NB!** Første gruppetime er mandag **2 september**

- ▶ **Gruppetimene:** Gruppelærerene er der for å hjelpe og veilede.
- ▶ **Piazza (diskusjonsforum):**
<https://piazza.com/uiuo.no/fall2019/in1140/>
NB! litt ventetid på svar
- ▶ **in1140-hjelp [at] ifi.uio.no:** Felles adresse til fag-/gruppelærere.



- ▶ Husk å sjekke **UiO-eposten** din og **beskjedlisten** på semestersiden.
- ▶ <http://www.uio.no/studier/emner/matnat/ifi/IN1140/h19/>



Hva er språkteknologi?



- ▶ Mål: å få datamaskiner til å 'forstå' naturlige språk.
- ▶ Aka:
 - ▶ computational linguistics (datalingvistikk)
 - ▶ language technology
 - ▶ language engineering
 - ▶ **natural language processing (NLP)**



Eksempler på språkteknologi?



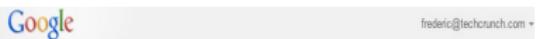
Eksempler på språkteknologi?



amazon.com

Recommended for You

Amazon.com has new recommendations for you based on items you purchased or told us you own.



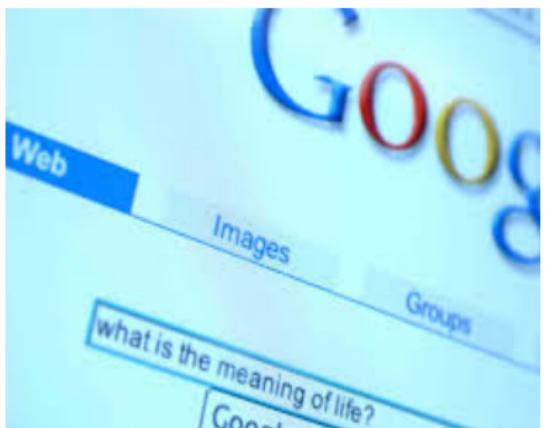
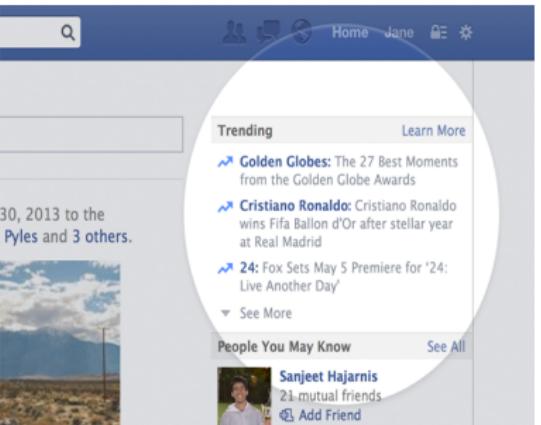
From: German To: English Translate

German English Spanish Detect language English Spanish Arabic

kammer	x
chamber	

New! Click the words above to edit and view alternate translations. Dismiss

noun	chamber	Kammer, Raum, Zimmer, Ge
■■■	room	Zimmer, Raum, Platz, Saal, t
■■■	cell	Zelle, Element, Kammer, Kla
■■■	professional association	Kammer
■■■	boxroom	Abstellkammer, Kammer



NLP er et tverrfaglig felt

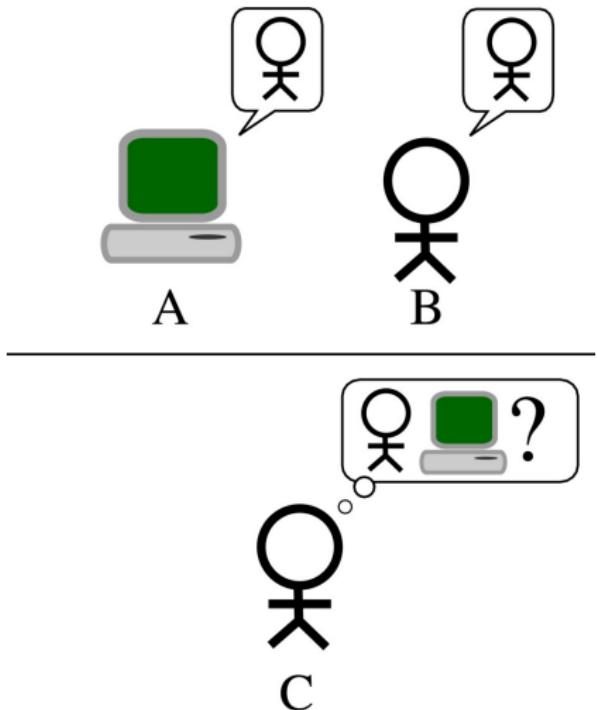
- ▶ Lingvistikk
 - ▶ Informatikk
 - ▶ Statistikk
 - ▶ Maskinlæring
 - ▶ Logikk, Filosofi, Psykologi, ...
-
- ▶ Del av det bredere feltet **kunstig intelligens** (AI).



Turingtesten

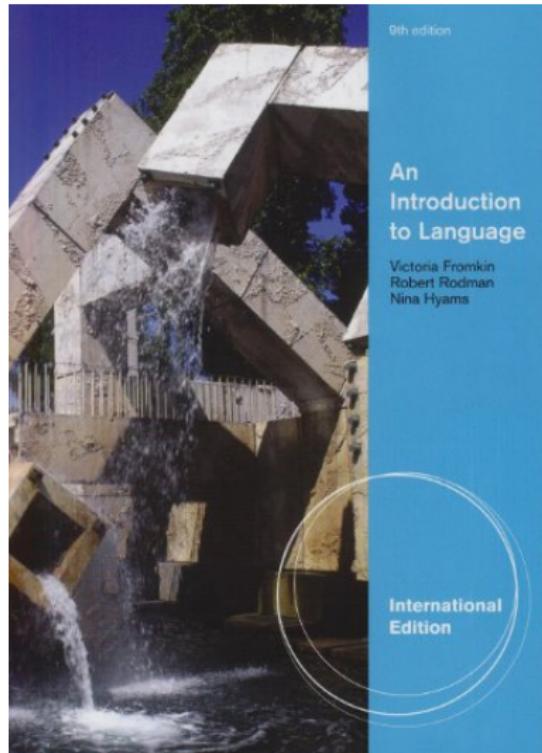


- ▶ Alan Turing i 1950:
- ▶ *I propose to consider the question, 'Can machines think?'*
- ▶ Definisjonsspørsmål. Skulle avgjøres ved Turingtesten.

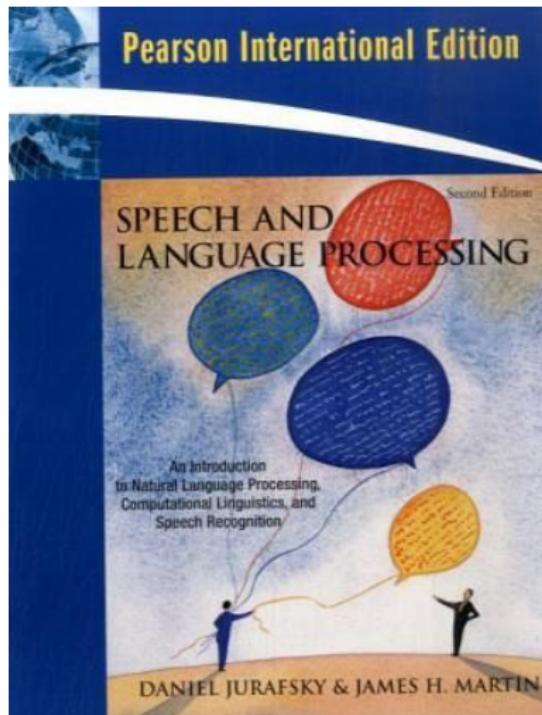


- ▶ Stoffet vi dekker i IN1140 tar også for seg stoff fra flere ulike felt.
- ▶ Innføring i **lingvistikk**,
- ▶ grunnleggende **sannsynlighetsregning**,
- ▶ **programmering**, og
- ▶ språkteknologiske **anvendelser**.

- ▶ Gjør deg godt rustet for flere viderekommende emner, f.eks
 - ▶ IN2110 – Språkteknologiske metoder
 - ▶ IN3050 – Kunstig intelligens og maskinlæring
 - ▶ IN3120 – Søketeknologi
 - ▶ og mange flere!



- ▶ *An Introduction to Language*
av Fromkin, Rodman & Hyams
- ▶ Utvalgte deler (ca 5 kapitler)

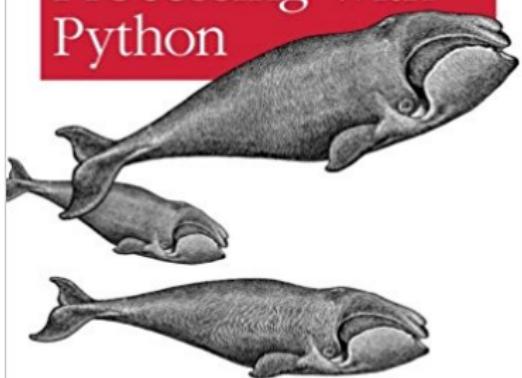


- ▶ *Speech and Language Processing*
av Jurafsky & Martin
- ▶ Utvalgte deler
- ▶ Gratis nettbok:
<https://web.stanford.edu/~jurafsky/slp3/>



Analyzing Text with the Natural Language Toolkit

Natural Language Processing with Python



O'REILLY®

Steven Bird, Ewan Klein & Edward Loper

- ▶ *Natural Language Processing with Python*,
av Bird, Klein & Loper
- ▶ Oppdatert for Python 3 og
NLTK 3 (Natural Language Toolkit)
- ▶ Utvalgte deler
- ▶ Gratis nettbok:
<http://www.nltk.org/book/>

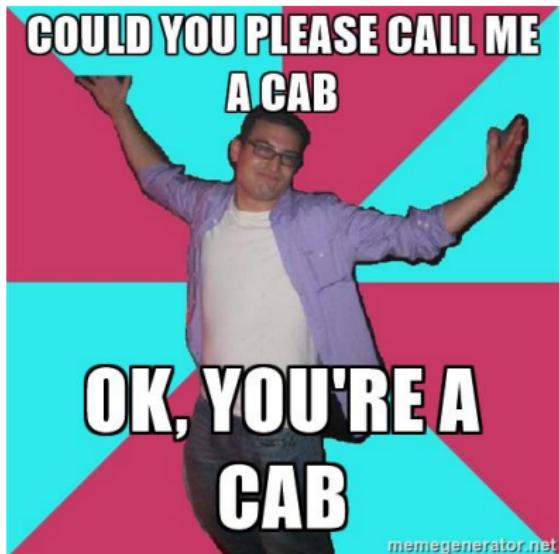
- ▶ Progammering lærer dere først og fremst i **IN1000**, ikke **IN1140**.
- ▶ **Forelesningene** i IN1140 kommer til fokusere på **teori**.
- ▶ Samtidig ønsker vi å implementere stoffet i praksis, i Python.
- ▶ **Implementasjon** blir fokus på **gruppene** og **innleveringene**.
- ▶ Kræsjkurs i Python-programmering på de første gruppetimeiene.
- ▶ Viktig med en del egeninnsats i starten for å henge med.



Hvorfor er språkforståelse utfordrende?



- ▶ Språk er vagt, ulike tolkninger mulig.
- ▶ Flertydighet overalt.
- ▶ Gir kompakt kommunikasjon:
- ▶ Samme uttrykk kan brukes i ulike kontekster.



- ▶ Flertydighetene er stort sett usynlige for oss, vi finner den intenderte tolkningen nærmest ubevisst.
- ▶ For maskiner er det motsatt: lett å finne alle mulige tolkninger, men vanskelig å se hvilken som er riktig.

Eksempel: Flertydighet på ordnivå

- Norsk: *rett*.
- Engelsk: ?
- Flertydig ift betydning + ordklasse (verb, subst., adj., adv.).
- Vi trenger kontekst for å avgjøre.

avgrenset av en **rett** linje tvers over kanalen

straight

Hva er **rett** svar?

correct, right

lovbestemt **rett** til innsyn

right

Denne **rett** avsa enstemmig dom i saken 4. juli 1980

court

Norsk **rett** tilpasses EUs regelverk

law

Vennligst **rett** disse prøvene!

grade, correct

Det bar **rett** i fengsel

directly, straight

De spiste en deilig **rett** av grønnsaker.

meal, dish

han var **rett** utenfor, **rett** nå

just

Slik skjer **rett** som det er.

må omskrives

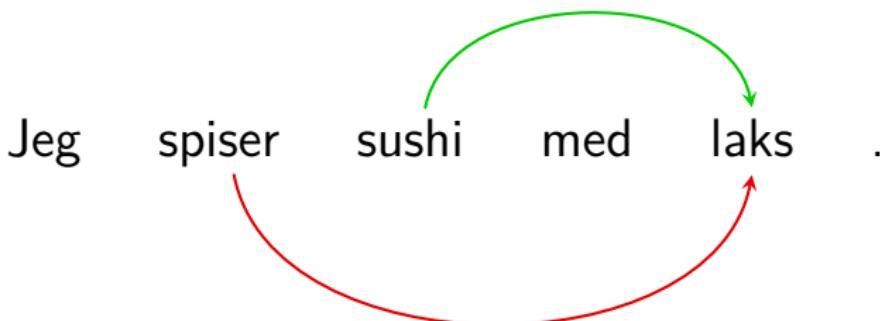
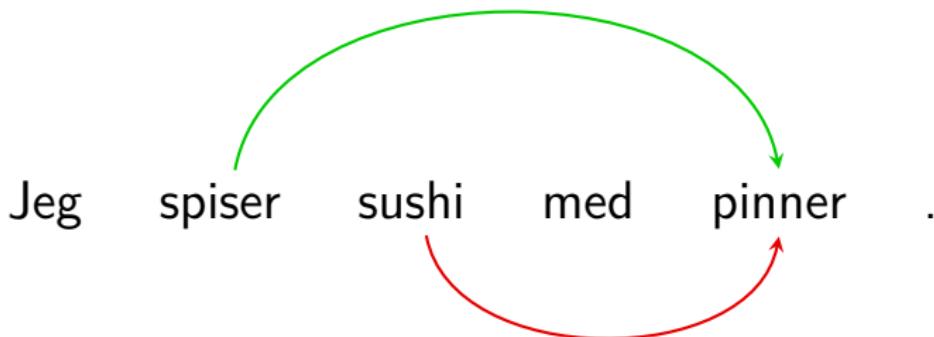
Eksempel: Flertydighet i referanse



We gave the monkeys, the bananas,
... because they, were hungry.
... because they, were ripe.



Flertydighet på setningsnivå



The main lesson of thirty-five years of AI research is that the hard problems are easy and the easy problems are hard. The mental abilities of a four-year-old that we take for granted — recognizing a face, lifting a pencil, walking across a room, answering a question — in fact solve some of the hardest engineering problems ever conceived... As the new generation of intelligent devices appears, it will be the stock analysts and petrochemical engineers and parole board members who are in danger of being replaced by machines. The gardeners, receptionists, and cooks are secure in their jobs for decades to come.

Steven Pinker, *The language instinct*

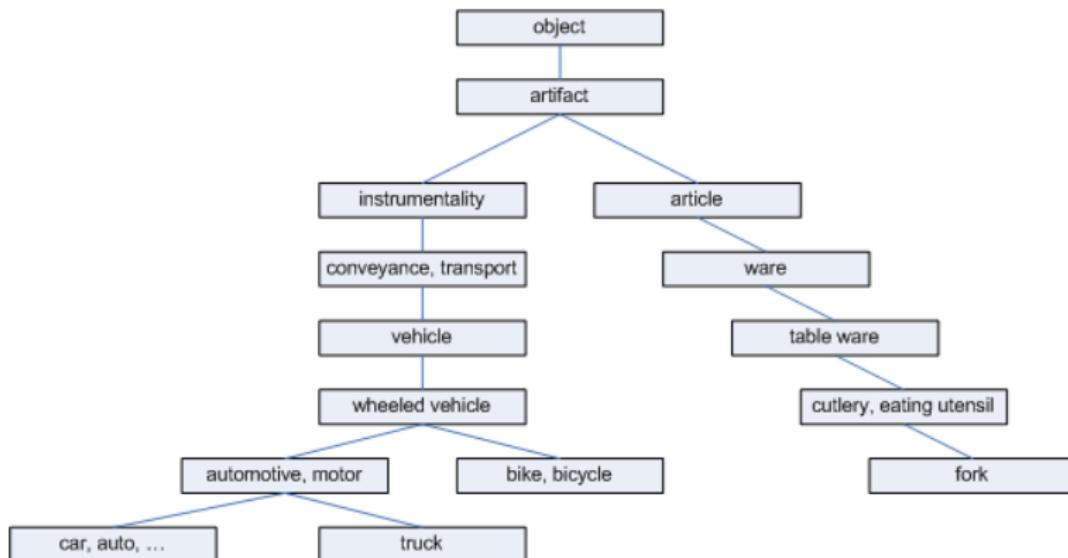
- En robot som bretter et håndkle (videoen er 50 ganger normal hastighet): <http://www.youtube.com/watch?v=gy5g33S0Gzo>

- ▶ Vi **mennesker** tolker språklige uttrykk basert på delt **bakgrunnskunnskap** og gjensidige **forventninger** i en gitt **kontekst**.
- ▶ **Språkforståelse** handler mye om **entydiggjøring**.
- ▶ Språkteknologi, og **IN1140**, handler i stor grad om strategier for hvordan maskiner kan takle dette.

Språktekniske metoder



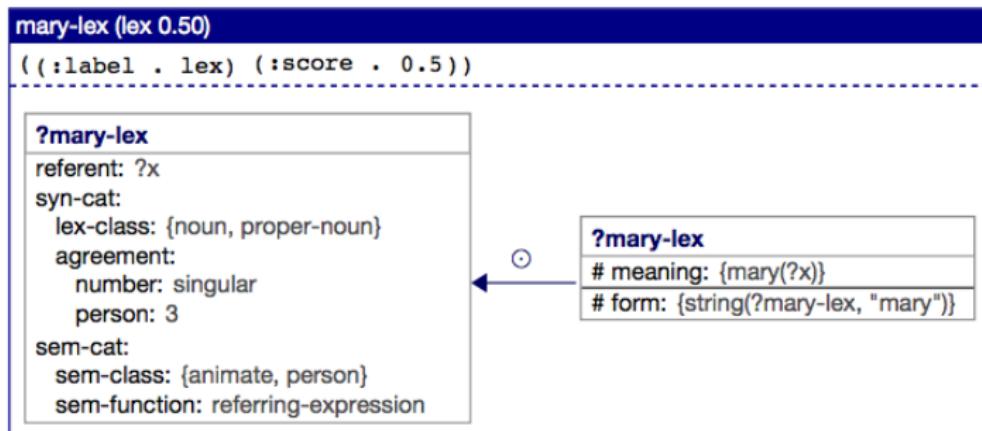
→ 2000-tallet: manuelt utformede regeler og leksikon



Språkteknologiske metoder



→ 2000-tallet: manuelt utformede regeler og leksikon



- 2000-tallet →: empirisk revolusjon

► Maskinlæring

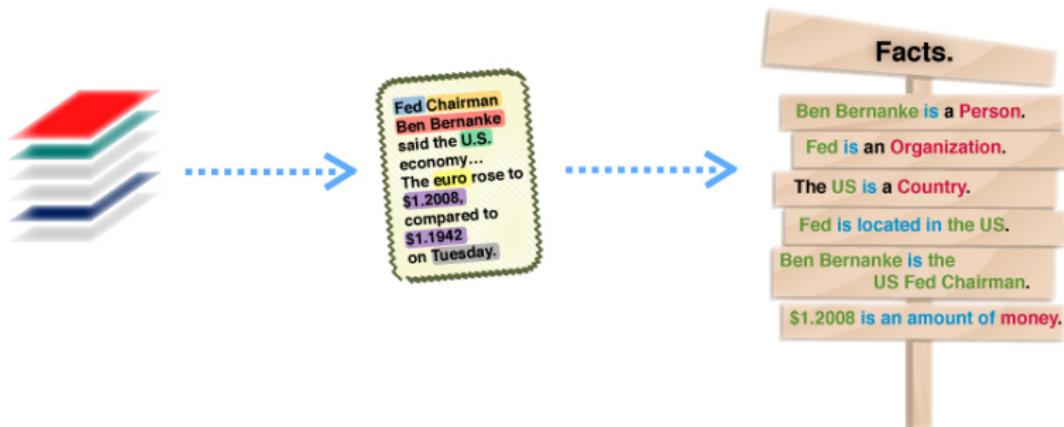
- Datamaskiner kan lære fra data: fange opp mønstre og generalisere til nye eksempler



Hva kan vi bruke språkteknologi til?



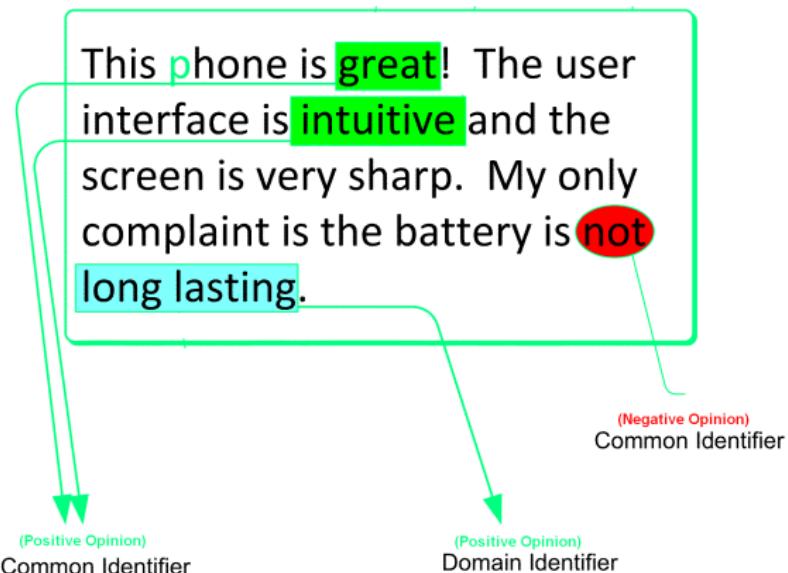
Informasjonsekstraksjon



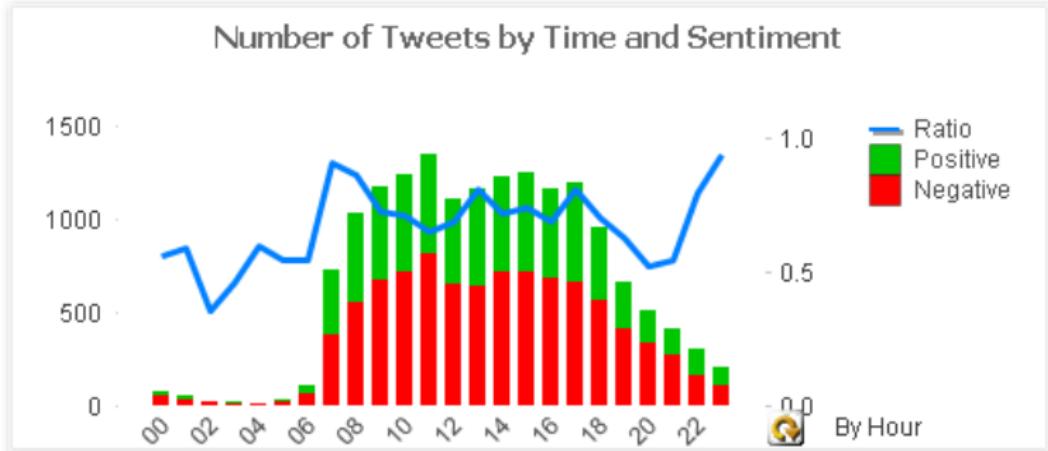
Sentiment Analyse



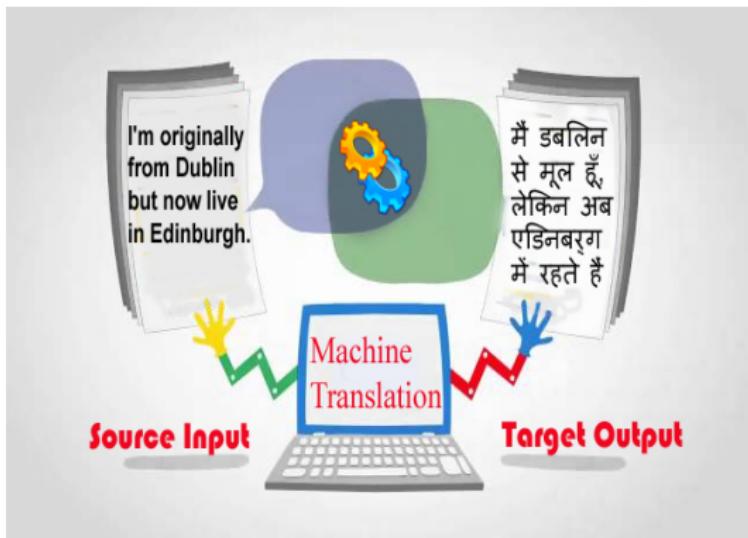
Automatisk analyse av subjektivt språk



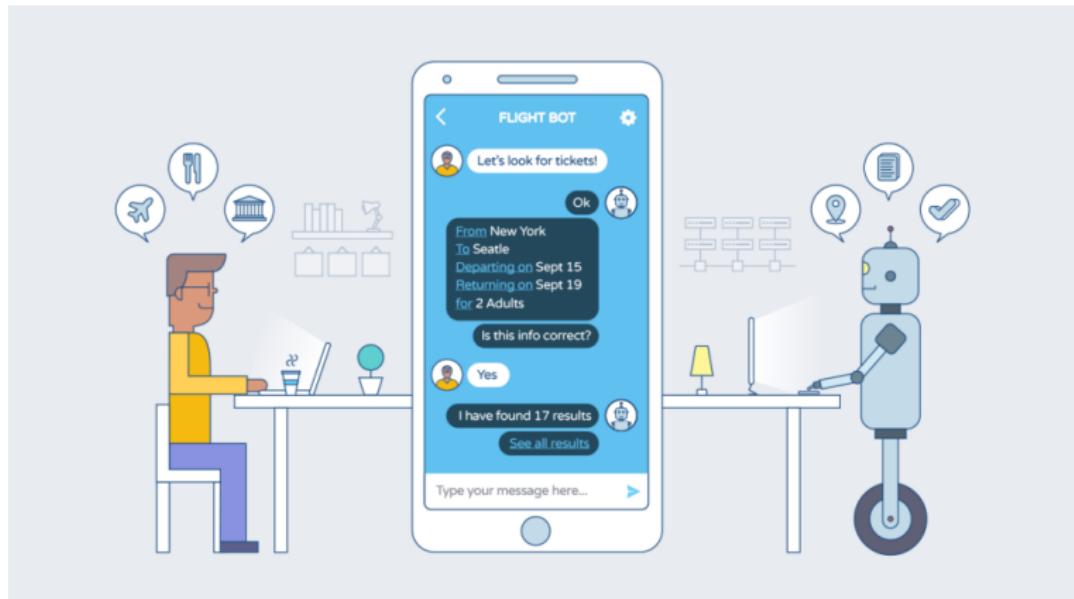
Medieovervåkning



Maskinoversettelse



Dialogsystemer



Obligatoriske innleveringer

- 3 obliger.
- Oblig 1 har to deler (a + b).
- Dvs. 4 innleveringer tilsammen: 1a + 1b, 2, 3.
- Alle obligene må bestås for å kunne ta eksamen.
- Ingen omlevering.

Poengsystemet

- Man kan oppnå opptil 100 poeng per innlevering
- For å bestå kreves minst 100 poeng (av 200 mulige) for oblig 1(a+b), og 50 poeng (av 100 mulige) for oblig 2 og 3.
- Eksempel:
 - 37 poeng på 1a
 - 68 poeng på 1b
 - = 105 poeng på oblig 2 (= bestått).

- ▶ **Absolutte frister:**
- ▶ Utsettes *kun* ved egenmelding (opptil 3 dager) eller legeerklæring.
- ▶ **Kopiering/plagiat godtas ikke.** Sett deg inn i reglene.
- ▶ Husk at hvis du distribuerer løsningsforslaget ditt på nett (f.eks via Github), kan du bidra til juks. Styr unna.
- ▶ Benytt deg av gruppeundervisningen, og planlegg tiden din.
- ▶ **Tidsregnskap:**
 - ▶ Arbeidsinnsats (minimum): $37,5 / 3 = 12,5$ timer
 - ▶ Etter forelesning+gruppe: 9,5 timer
- ▶ **Konkurranse:** den/de som får flest poeng tilsammen på obligene gjennom semesteret får en premie (overraskelse)!

- ▶ Skriftlig (digital) eksamen på fire timer
 - ▶ 27 november kl. 14:30
- ▶ Pensumlitteratur + forelesningsnotater
- ▶ **NB! Ikke en programmeringseksamen.**
- ▶ Fokus på teoretiske konsepter.

Suksessoppskrift

- ▶ Emnesiden: timeplan, pensum, lesehenvisninger, beskjeder etc.
- ▶ Lesehenvisninger: forbered deg til forelesning
- ▶ Still spørsmål
- ▶ Gruppetime:
 - ▶ forbered deg
 - ▶ delta aktivt
 - ▶ gjør oppgaver (også de ikke-obligatoriske!)
- ▶ Benytt deg av medstudentene dine

