

Interaktive systemer


Pierre Lison
plison@nr.no

IN2110: Språkteknologiske metoder
27. april 2022



Oblig 2b

- ▶ 2 deler:
 - **MT:** Oversettelseksperimenter med filmtekstinger fra Ringenes Herre (tysk → engelsk)
 - **Interaktive systemer:** utvikling av en veldig enkel, datadrevet praterobot (trent på filmtekstinger)



- ▶ Oppgaven skal publiseres i de neste dagene
- ▶ Innleveringsfrist: **16. mai**

Plan for i dag

- ▶ Introduksjon
- ▶ Hva er en samtale?
- ▶ Prateroboter
 - Regelbaserte systemer
 - IR og seq2seq modeller
 - Intentgjenkjenning
- ▶ Dialogstyring
- ▶ Etske betrakninger

Plan for i dag

- ▶ **Introduksjon**
- ▶ Hva er en samtale?
- ▶ Prateroboter
 - Regelbaserte systemer
 - IR og seq2seq modeller
 - Intentgjenkjenning
- ▶ Dialogstyring
- ▶ Ethiske betrakninger

Dialogsystemer?

= dataprogrammer ("bots") utviklet til å samhandle med mennesker ved hjelp av (talte eller tekstbaserte) naturlige språk

Dialogsystem

brukerytring



maskinytring

Hvorfor?

- *Brukervennlig*: du trenger bare å kunne snake/skrive!
- Kan utrykke *komplekse forespørsler*
- For talebaserte systemer: *berøringsfri grensesnitt* (viktig for f.eks. bilkjøring)

Anvendelser

Virtuelle assistenter
(Siri, Cortana, osv.)



Smarthusprodukter



Stemmebasert navigering
og styring i bilen



Lærings
platformer



Praterobotter




Tjenesteroboter



Plan for i dag

- ▶ Introduksjon
- ▶ **Hva er en samtale?**
- ▶ Prateroboter
 - Regelbaserte systemer
 - IR og seq2seq modeller
 - Intentgjenkjenning
- ▶ Dialogstyring
- ▶ Etske betrakninger



Turtaking (turn-taking)

- ▶ Deltakerne i dialog tar *turer*:
 - En tur = et kontinuerlig bidrag fra en samtalepartner
- ▶ Turtaking er en beskrivelse av hvordan ordet fordeles mellom samtalepartnere
- ▶ Overraskende flytende i dagligdagssamtaler
 - Forsøk på å minimere både tomrom (ingen som snakker) og overlapp (flere som snakker over hverandre)
- ▶ Intervallet mellom turer er rundt 250 ms

[Duncan (1972): «Some Signals and Rules for Taking Speaking Turns in Conversations», in *Journal of Personality and Social Psychology*]

Turtaking

- ▶ Hvordan er turer tildelt (tatt/frigitt)?
- ▶ Ulike markører:
 - Komplette syntaktisk/semantisk enhet?
 - Dialogstruktur (hilsen → hilsen, spørsmål → svar osv.)
 - Intonasjon (fallende intonasjon signaliserer ofte at turen er ferdig)
 - Ikke-verbale signaler som blikk, gester
 - Markører for stillhet og nøling som "eh" (utfylte pauser ≠ fylte pauser)
 - Sosiale konvensjoner



My Turn




Your Turn

Eksempel av turtaking


Person 1:	han vil bo i skogen ?
Person 2:	# altså hvis jeg hadde kommet og sagt " skal vi flytte i skogen ? " så hadde han sagt ja
Person 1:	mm
Person 2:	men jeg vil ikke bo i skogen
Person 1:	nei det skjønner jeg
Person 2:	så vi må jo finne et sted som er mellomting og det jeg vil ikke bo utpå landet # i hvilken som helst (uforståelig) ...
Person 1:	* men det kommer jo an på hvor i skogen da

Språkhandlinger

- ▶ Hver ytring er en **handling** utført av taleren
- ▶ Taleren har et spesifikt mål (som kanskje "bare" er å etablere eller opprettholde et sosial kontakt med samtalepartnere)
- ▶ Ytringer leder til bestemte *virkninger* på samtalepartnere (eller på verden forøvrig)
- ▶ «Språk som handling» -perspektiv



J.L. Austin (1911-1960)
språkfilosof



J. Searle (1932, -)
språkfilosof

Språkhandlinger




- ▶ Morens reaksjonen har et bestemt *formål*, nemlig å formidle hennes forbauselse/sinne og stoppe Calvin
- ▶ Spørsmålet hennes leder til bestemte virkninger:
 - En psykologisk reaksjon fra Calvin (overraskelse)
 - + en virkning på selve verdenen (Calvin stopper)

Searles taksonomi

- ▶ **Assertives** : committing the speaker to the truth of a proposition. E.g.: «*Eksamen vil finne sted 3. juni*»
- ▶ **Directives**: attempts by the speaker to get the addressee to do something. E.g. : «*Kan du rydde opp soverommet ditt?*»
- ▶ **Commissives**: committing the speaker to some future course of action. E.g.: «*Jeg lover deg å rydde opp rommet mitt*».
- ▶ **Expressives**: expressing the psychological state of the speaker. E.g.: «*Takk for at du ryddet opp rommet ditt*».
- ▶ **Declaratives**: bringing about a different state of the world by the utterance. E.g.: «*Du er sparket.*».

Grounding


- ▶ Dialog er et samarbeid mellom deltakerne i samtalen
 - Trenger å sikre gjensidig forståelse – "vi er på samme linje"
- ▶ Gradvis utvidelse og berikelse av vår "common ground"
- ▶ "common ground" = kunnskap som er felles for samtaledeltakerne




[H. H. Clark and E. F. Schaefer (1989),
«Contributing to discourse», in *Cognitive Science*]

Grounding

- ▶ Grounding betegner prosessen av å gradvis utvide vår "common ground" i løpet av samtalen
 - Bred register av signaler og strategier
- ▶ Flere nivåer
 - Kontakt (oppmerksomhet overfor partneren)
 - Oppfatning av ytringen
 - Forståelse av ytringen
 - Holdninger (enighet, empati osv.)



Herbert H. Clark
psykolingvist



Jens Allwood
lingvist

[Jens Allwood (1992), «On discourse cohesion», in *Gothenburg papers in Theoretical Linguistics.*]

Grounding actions

- ▶ Backchannels: «*uh-uh*», «*mm*», «*ja*»
- ▶ Eksplisitte tilbakemeldinger: «*ja det skjønner jeg*»
- ▶ Implisitte tilbakemeldinger: A: «*Jeg ønsker å fly til Roma*» → B: «*På onsdag er det to flyvninger til Roma: ...* »
- ▶ Klarifiseringsstrategier: «*Mente du til Roma eller til Goa?*», "*Kan du bekrefte at ...* "
- ▶ Fiksingsstrategier: «*OK, dere ønsker altså ikke å fly til Goa. Hvor ønsker dere å fly da?*»

Eksempel av grounding

Person 1:	vi vasker den hver dag vi # vi har mopp
Person 2:	mm ## ja det er fort og faren til M27 legger nytt teppe han # det er gjort på to timer ## så det er fort gjort
Person 1:	ja ## da er ikke noe sak
Person 2:	vi har skifta teppe tre ganger allerede han gjør det gratis
Person 1:	hæ ?
Person 2:	vi har skifta teppe tre ganger og # han han ...
Person 1:	* jeg skjønner ikke hvorfor dere har teppe
Person 2:	jeg syns det var rart jeg òg # men e # (sibilant)

Eksempel av grounding (2)

Person 1:	e # nei det er ikke mange
Person 2:	ja * nei
Person 1:	men heldigvis så var ikke Petter Rudi tatt ut denne gangen da
Person 2:	ja # jeg skjønner ikke hva han skal på landslaget å gjøre
Person 1:	* nei han har ingen ting på landslaget
Person 2:	nei # definitivt
Person 1:	å gjøre # han er ubrukelig
Person 2:	* moldensere
Person 1:	hm?
Person 2:	ja disse moldenserne
Person 1:	en gang til?
Person 2:	disse moldenserne
Person 1:	* å ja (fremre klikkelyd) # unnskyld # jeg hørte ikke hva du sa

Implisitt tilbakemelding
(gjentakelse av *landslaget*)

klarifisering



Plan for i dag

- ▶ Introduksjon
- ▶ Hva er en samtale?
- ▶ **Prateroboter**
 - **Regelbaserte systemer**
 - **IR og seq2seq modeller**
 - **Intentgjenkjenning**
- ▶ Dialogstyring
- ▶ Ethiske betrakninger

Grunnarkitektur

Brukerens "intent"

NLU (Natural Language Understanding)

Generation / response selection

inngangssignal
(brukerytring)

utgangssignal
(maskinytring)



Bruker

Regelbaserte systemer

- ▶ Pattern-action rule:

(0 YOU 0 ME) [*pattern*]

→

(WHAT MAKES YOU THINK I 3 YOU) [*transform*]

- ▶ For eksempel:

You hate me

WHAT MAKES YOU THINK I HATE YOU

IR modeller

- ▶ Alternativ: bruke en datadrevet tilnærming og svare brukeren basert på et *dialogkorpus*
- ▶ Prosedyren:
 - Gitt en brukerinngang **q**, finn ytringen **t** i dialogkorpuset som ligner mest på **q**
 - Så returner som svar enten (a) selve **t** eller (b) ytringen som følger **t** i korpuset

IR modeller

$$r = \text{response} \left(\underset{t \in C}{\operatorname{argmax}} \frac{q^T t}{\|q\| \|t\|} \right)$$

Hvordan kan vi bestemme hvilken ytring \mathbf{t} fra korpuset «ligner mest» på inputytringen \mathbf{q} ?

- ▶ Cosine similarity mellom vektorer
- ▶ Vektorene kan være TF-IDF vektorer (hvor hver ytring tilsvarer et eget "dokument")
- ▶ Eller embeddings beregnet fra et nevralt nettverk

Eksempel

TF vektorer:

Korpuset:

1. hei ! →
2. hei ! har du det bra ? →
3. ja , hva med deg ? →
4. bare bra →
5. har du spist ? →
6. ja →

	bare	bra	deg	det	du	ja	har	hei	hva	med	spist	,	!	?
1. hei !								1					1	
2. hei ! har du det bra ?		1		1	1		1	1					1	1
3. ja , hva med deg ?			1			1			1	1		1		1
4. bare bra	1	1												
5. har du spist ?					1		1				1			
6. ja						1								

Eksempel

$$\log(6) \approx 0.78$$

$$\log\left(\frac{6}{2}\right) \approx 0.48$$

TF-IDF vektorer:

Korpuset:

1. hei ! →
2. hei ! har du det bra ? →
3. ja , hva med deg ? →
4. bare bra →
5. har du spist ? →
6. ja →

	bare	bra	deg	det	du	ja	har	hei	hva	med	spist	,	!	?
1. hei !								.48					.48	
2. hei ! har du det bra ?		.48		.78	.48		.48	.48					.48	.48
3. ja , hva med deg ?			.78			.48			.78	.78		.78		.48
4. bare bra	.78	.48												
5. har du spist ?					.48		.48				.78			
6. ja						.48								

Ny brukerinput q : "går det bra med deg?"


TF-IDF vektor:

	.48	.78	.78							.78				.48
--	-----	-----	-----	--	--	--	--	--	--	-----	--	--	--	-----



Eksempel

	bare	bra	deg	det	du	ja	har	hei	hva	med	spist	,	!	?
1.								.48					.48	
2.		.48		.78	.48		.48	.48					.48	.48
3.			.78			.48			.78	.78		.78		.48
4.	.78	.48												
5.					.48		.48				.78			
6.						.48								



	.48	.78	.78						.78					.48
--	-----	-----	-----	--	--	--	--	--	-----	--	--	--	--	-----

Eksempel

$$\frac{q^T t}{\|q\| \|t\|}$$

Korpuset:

1.	hei !	→	0
2.	hei ! har du det bra ?	→	0.50
3.	ja , hva med deg ?	→	0.56
4.	bare bra	→	0.17
5.	har du spist ?	→	0
6.	ja	→	0

→ Det betyr at ytringen som ligner mest på q er ytringen 3: "ja, hva med deg?"


... og at systemet kan velge som respons ytringen som kommer rett etter 3

Ny brukerinput q : "går det bra med deg?"

↳ **Respons fra systemet: "bare bra"**

Seq2seq modeller


- ▶ IR modeller kan kun velge ytringer fra korpuset
- ▶ Seq2seq modeller kan generere *nye* ytringer, ord for ord
 - Veldig lik modellene brukt for maskinoversetelse
 - Skritt 1: konvertere brukerytringen til en vektor (*encoding*)
 - Skritt 2: generere svaret ord for ord (*decoding*)



Eksempel fra "Meena" (Google)


Seq2seq modeller: ←

- + Kan produsere helt «nye» svar
- Vanskelig å «styre» (hva kommer systemet til å svare, og hvorfor?)



<https://ai.googleblog.com/2020/01/towards-conversational-agent-that-can.html>

Hybride arkitekturer



Mange prateroboter utviklet av/for virksomheter tar i bruk en hybrid arkitektur hvor:

- ▶ NLU-komponenten er trent fra markerte data (klassifiseringsproblem: koble brukerytringen til dets *intent*)
- ▶ Svarene er forhåndsskrevet av utvikleren

Intentgjenkjenning

Definert fra en liste
forhåndsdefinerte kategorier
(muligens med argumenter,
ofte kalt slots)

- ▶ *Input*: selve brukerytringen (+ kontekst)
- ▶ *Output*: **intent** (= hva brukeren forsøker å oppnå)

Intent=

GetInfoOpenHours(RecyclingStation)

Intent
recognition

Response
selection

"When is the
recycling
station open?"




"The recycling station is open
on weekdays from 10 to 18"

Plan for i dag


- ▶ Introduksjon
- ▶ Hva er dialog?
- ▶ Prateroboter
 - Regelbaserte systemer
 - IR og seq2seq modeller
 - Intentgjenkjenning
- ▶ **Dialogstyring**
- ▶ Ethiske betrakninger

Dialogstyring



- ▶ **Begrensning av prateroboter:** ofte ingen/lite "minne" av samtalehistorikk (utover den gjeldende ytringen)
- ▶ Vanskelig å skalere til mer kompliserte interaksjoner, hvor samtalen kan utfolde seg på mange "turer"

Dialogstyring




= Tar ansvar for *flyten* av samtalen over tid

- Styre turtakingen
- Sikre gjensidige forståelse ("grounding")
- Oppdatere representasjonen av *dialogtilstanden* jevnlig
- Finne ut hva systemet bør si eller gjøre på et vist tidspunkt

Endelige tilstandsmaskiner

Enkleste dialogstyringsmetode: *endelig tilstandsautomata*


- ▶ Hver node representerer en spesifikk *dialogtilstand*, og er assosiert med en systemrespons
- ▶ Hver kant representerer en mulig svar fra brukeren, og brukes til å bevege systemet fra tilstand til tilstand



Interaksjonsstyl

Begrensninger ved endelige tilstandsmaskiner og lignende metoder:


- ▶ Stiv, repetitiv (og ofte irriterende) adferd
- ▶ Ikke egnet til å handtere støy og usikkerhet
- ▶ Ingen bruker- eller domenetilpasning
- ▶ Begrenset til et mål ... men reelle interaksjoner er *avveininger* mellom ulike (konkurrerende) hensyn



“Saturday night live” sketch comedy, 2005

Datadrevet dialogstyring

- ▶ **Løsning:** automatisk optimere dialogstyring ut fra erfaringer samlet av systemet
 - Ofte basert på *reinforcement learning*
 - "Erfaringer" = samtaler med enten ekte eller simulerte brukere
 - Samtaler er belønnet med positive og negative tilbakemeldinger (*rewards*)
- ▶ Dessverre ikke tid til å beskrive slike modeller i dag!



Plan for i dag

- ▶ Introduksjon
- ▶ Hva er en samtale?
- ▶ Prateroboter
 - Regelbaserte systemer
 - IR og seq2seq modeller
 - Intentgjenkjenning
- ▶ Dialogstyring
- ▶ **Etiske betraktninger**

Etiske betrakninger

- ▶ Maskinlærings kan gjenskape (og noen ganger forsterke) skjevheter som oppstod i treningsdataene
 - Hatytringer, fordommer, krenkende språk, kjønnskjevhet, osv.
- ▶ Hvordan beskytte brukerens personvern?
- ▶ Forsterker virtuelle assistenter kjønnsstereotyper?
- ▶ Hvordan unngå at prateroboter brukes til å bedra folk?

«Nei Siri, det kan du ikke si!»,

<https://blogg.forskning.no/akademiet-for-yngre-forskere>