

AI för naturligt språk

Vad är naturligt språk-behandling?

Marco Kuhlmann

Institutionen för datavetenskap

Vad är naturligt språk-behandling?

- **Naturligt språk-behandling** utvecklar metoder för att förstå och producera mänskligt språk med hjälp av datorer.

eng. natural language processing (NLP)

- Några välkända tillämpningar av naturligt språk-behandling är smarta sökmotorer, maskinöversättning och digitala assistenter.
- I den här kursen kommer vi att fokusera på behandling av naturligt språk i textform (snarare än talat språk).


Google search results for "naturligt språk-behandling".

Search results include:

- Inom Natural Language Processing (NLP) är fokus på semantik och tekniska system med förmåga att förstå mänskligt/naturligt språk, vilket inkluderar automatisk tolkning av innebörd genom analys av beroenden, identifiering av referenser och temporal ordning.** 6 Nov 2015
- Naturligt språkbehandling | Datavetenskap** (cs.lth.se)
- Den växande marknaden för naturligt språkbehandling | by ...** (medium.com)
- naturligt språk behandling verktyg - Dator** (dator8.info)
- Behandling av naturliga språk – AI Competence for Sweden** (ai-competence.se)
- Naturlig språkbehandling - Natural language processing - qaz ...** (sv.qaz.wiki)
- 8 bra Pythonbibliotek för NLP – behandling av naturliga språk ...** (techworld.idg.se)
- Naturligt språkbehandling - Swedish definition, grammar ...** (en.glosbe.com)
- Naturliga språkbehandlingsverktyg - dumay** (www.dumay.info)


Right sidebar: "Natural language processing (Naturligt språk-behandling)" with a description and a list of related terms: Model, Technology, Programs, Textbook. Below is "People also search for" with icons for Machine learning, Artificial intelligence, Computer vision, Artificial neural network, and Internet of things.

Kunskapsglappet



Jeopardy!

Hon är känd för sitt arbete inom naturligt språk-behandling och föddes i Huddersfield.



University of Cambridge, CC BY 2.0, via Wikimedia Commons

[SPARQL-sökfråga mot DBPedia](#)

```
SELECT DISTINCT ?x WHERE {  
  ?x dbo:knownFor dbr:Natural_language_processing.  
  ?x dbo:birthPlace dbr:Huddersfield.  
}
```

AI för naturligt språk


Två paradigmer

Marco Kuhlmann

Institutionen för datavetenskap

Jeopardy!

Hon är känd för sitt arbete inom naturligt språk-behandling och föddes i Huddersfield.



University of Cambridge, CC BY 2.0, via Wikimedia Commons

[SPARQL-sökfråga mot DBPedia](#)

```
SELECT DISTINCT ?x WHERE {  
  ?x dbo:knownFor dbr:Natural_language_processing.  
  ?x dbo:birthPlace dbr:Huddersfield.  
}
```

Två paradigmer

Eisenstein (2019), § 1.2.1

- **Lingvistisk kunskap**

Bygga kedjor av systemkomponenter som producerar lingvistiskt motiverade representationer.

ordklasser, syntaxträd, semantiska representationer

- **Djupinlärning**

Träna djupa neuronnet som direkt transformerar rå text till den struktur som tillämpningen behöver.

Lingvistiska representationer




dbr:Karen_Sparck_Jones dbo:birthPlace dbr:Huddersfield


Lingvistiska representationer



'Natural language processing from scratch'



[Vaswani et al. \(2017\)](#)



[Tenney et al. \(2019\)](#)

AI för naturligt språk

Sökning och inläring

Marco Kuhlmann

Institutionen för datavetenskap

Sökning och inlärning

översättning
till engelska

predicerat utvärde

invärde

mening
på svenska

$$\hat{y} = \operatorname{argmax}_{y} \operatorname{score}(x, y; \theta)$$

y
möjligt
utvärde

mening på engelska

modell-
parametrar

sannolikheter, vikter

Sökning och inläring

Eisenstein (2019), § 1.2.2

- **Sökkomponenten**

Sökkomponenten ansvarar för att hitta det utvärde y som har högst poäng relativt till invärdet x och modellparametrarna θ .

kräver effektiva algoritmer

- **Inlärningskomponenten**

Inlärningskomponenten ansvarar för att hitta de modellparametrar θ som maximerar systemets kvalitet.

ofta någon form av övervakad maskininläring

Sökning och inlärning


Jag	bad	om	en	kort	bit
PRON	VERB	ADP	DET	ADJ	NOUN
NOUN	NOUN	SCONJ	NUM	ADV	VERB
		ADV	PRON	NOUN	
			NOUN		

Exempel från Joakim Nivre

Sökning och inläring

Jag	bad	om	en	kort	bit
PRON	VERB	ADP	DET	ADJ	NOUN
95,83%	50,00%	63,16%	92,52%	66,67%	100,00%
NOUN	NOUN	SCONJ	NUM	ADV	VERB
4,17%	50,00%	35,93%	4,64%	33,33%	0,00%
		ADV	PRON	NOUN	
		0,92%	2,85%	0,00%	
			NOUN		
			0,00%		

Sökning och inlärning




Vikterna i neuronnätet sätts med hjälp av en inlärningsalgoritm.

AI för naturligt språk

NLP i ett bredare perspektiv

Marco Kuhlmann

Institutionen för datavetenskap



Callaghan Innovation: AI Demystified (2017)

Kommersiellt intresse

Bloomberg®

Google



amazon | science



Megagon Labs

Baidu 百度

DeepMind

IBM

FACEBOOK AI

Kommersiellt intresse

Andra AP-fonden • Bonnier • Consid • Doctrin

Ericsson • Etteplan • Findwise

Fodina Language Technology • Gavagai • lamIP

iMetrics • Modular Finance • Opera Software

Redeye • Saab • Schibsted • Sectra • Spotify

Storytel • Visma

Etiska frågeställningar

New AI fake text generator may be too dangerous to release, say creators

The Elon Musk-backed nonprofit company OpenAI declines to release research publicly for fear of misuse



▲ The AI wrote a new passage of fiction set in China after being fed the opening line of *Nineteen Eighty-Four* by George Orwell (pictured). Photograph: Mondadori/Getty Images

The creators of a revolutionary AI system that can write news stories and works of fiction - dubbed "deepfakes for text" - have taken the unusual step of not releasing their research publicly, for fear of potential misuse.

[The Guardian \(2019-02-14\)](#)

Miljö och hållbarhet

Consumption	CO₂e (lbs)
Air travel, 1 person, NY↔SF	1984
Human life, avg, 1 year	11,023
American life, avg, 1 year	36,156
Car, avg incl. fuel, 1 lifetime	126,000
Training one model (GPU)	
NLP pipeline (parsing, SRL)	39
w/ tuning & experiments	78,468
Transformer (big)	192
w/ neural arch. search	626,155

Table 1: Estimated CO₂ emissions from training common NLP models, compared to familiar consumption.¹

[Strubell et al. \(2019\)](#)


AI för naturligt språk

Linjär regression

Marco Kuhlmann

Institutionen för datavetenskap

Linjär regression



Linjär regression

- **Modell**

Sambandet mellan prediktorn (boendeyta) och den predicerade variabeln (pris) kan beskrivas som en linjär funktion.


räta linjens ekvation

- **Optimering**



Hitta den mest anpassade linjära funktionen – den funktion som minimerar modellens fel, relativt till data.

felfunktion: kvadratisk medelfel



Linjär modell – räta linjens ekvation





Felfunktion – kvadratisk medelfel



Felfunktion – kvadratisk medelfel



Felfunktion – kvadratisk medelfel




AI för naturligt språk

Generaliserad linjär regression

Marco Kuhlmann

Institutionen för datavetenskap

Linjär regression



Linjär regression

Boendeyta (x)	Pris (y)
2 104	399 900
1 600	329 900
2 400	369 000
1 416	232 000
...	...

Linjär regression med flera prediktorer

	Boendeyta (x_1)	Antal sovrum (x_2)	Pris (y)
x	2 104	3	399 900
	1 600	3	329 900
	2 400	3	369 000
	1 416	2	232 000

$$\mathbf{x} = [x_1 \quad x_2] = [2104 \quad 3]$$

Linjär regression med flera prediktorer

- **Modell**

Sambandet mellan prediktorerna (boendeyta, antal sovrum) och den predicerade variabeln (pris) är linjärt.


allmän linjär funktion

- **Optimering**


Hitta den mest anpassade linjära funktionen – den funktion som minimerar modellens fel, relativt till data.

felfunktion: genomsnittligt kvadratfel

Linjär regression med flera prediktorer




Den generaliserade linjära modellen



$$y_1 = x_1 w_{11} + x_2 w_{21} + b_1$$

$$y_2 = x_1 w_{12} + x_2 w_{22} + b_2$$

Den generaliserade linjära modellen



Räkneexempel

$$\mathbf{x} = [1 \quad 4] \quad \mathbf{W} = \begin{bmatrix} 2 & 5 & 2 \\ 7 & 3 & 5 \end{bmatrix} \quad \mathbf{b} = [0 \quad 1 \quad 0]$$

$$\mathbf{xW} = [1 \cdot 2 + 4 \cdot 7 \quad 1 \cdot 5 + 4 \cdot 3 \quad 1 \cdot 2 + 4 \cdot 5] = [30 \quad 17 \quad 22]$$


$$\mathbf{xW} + \mathbf{b} = [30 \quad 18 \quad 22]$$

Linjära neuronnät

matematisk modell

$$y = xW + b$$

grafisk notation




AI för naturligt språk

Gradientsökning

Marco Kuhlmann

Institutionen för datavetenskap

Linjär regression




Hur hitta den bästa linjära modellen för datat?


- För att få en ungefärlig lösning kan vi för hand rita in en rät linje och sedan beräkna dess lutning och baskonstant.
- För att få en exakt lösning kan vi använda minsta kvadratmetoden, som finns bl.a. på många grafritande miniräknare.
- Ett annat sätt att lösa uppgiften är att använda sig av en approximativ, numerisk metod: **gradientsökning**.

gradient = generalisering av derivata till fler än en oberoende variabel

Gradientsökning – intuition




subtrahera
ett relativt stort värde




addera
ett relativt litet värde

Gradientsökning – intuition



subtrahera
felfunktionens gradient




subtrahera
felfunktionens gradient

Gradientsökning

1. Börja med framslumpade modellparametrar
2. Beräkna felfunktionens gradient för den aktuella uppsättningen modellparametrar, relativt till datapunkterna
förutsätter att felfunktionen är deriverbar
3. Uppdatera modellparametrarna genom att subtrahera gradienten
4. Upprepa steg 2–3 tills felvärdet är tillräckligt lågt

Gradientsökning




modell	felvärde	gradient
2,000	2,33	4,67

steglängdsfaktor = 0,1

subtrahera 0,467

Gradientsökning




modell	felvärde	gradient
2,000	2,33	4,67
1,533	0,66	2,49

steglängdsfaktor = 0,1

subtrahera 0,249

Gradientsökning




modell	felvärde	gradient
2,000	2,33	4,67
1,533	0,66	2,49
1,284	0,19	1,33

steglängdsfaktor = 0,1

subtrahera 0,133

Gradientsökning



modell	felvärde	gradient
2,000	2,33	4,67
1,533	0,66	2,49
1,284	0,19	1,33
1,151	0,05	0,71

steglängdsfaktor = 0,1

subtrahera 0,071

Den osannolika effektiviteten av gradientsökning

- Om felfunktionen är konvex kommer gradientsökningen hitta en optimal uppsättning parametrar.

Kvadratisk medelfel är en sådan konvex felfunktion.

- De flesta felfunktioner är *inte* konvexa, och det finns ingen garanti att gradientsökning kommer hitta en optimal lösning.
- I praktiken är det dock så att gradientsökning fungerar förvånansvärt bra när den används för att träna neuronnät.

många tekniska tricks