

AI för naturligt språk

Introduktion till textklassificering

Marco Kuhlmann

Institutionen för datavetenskap

Textklassificering

- **Textklassificering** handlar om att automatiskt sortera textdokument i fördefinierade klasser.
- Begreppet *dokument* används på alla sorters texter, från korta twitterinlägg till fullständiga böcker.
- För att träna och utvärdera textklassificerare krävs dokument som är annoterade med rätt klass.

Textklassificering kan inte upptäcka egna klasser.

Sentimentanalys

Men den välanvända tropen och välbekanta strukturen till trots är ”Palm Springs” en riktig liten pärla, genomförd med både finesse och ett stort känslomässigt gehör. Det är ... en berättelse som vibrerar av hjärta och smartness under sin småfåniga exteriör.

Källa

positiv

Tyvärr är ”Bliss”, utöver det ganska vackra fotot, en enda röra. Den överlastade, men svårt undergestaltade, intrigen solkas av kass dialog och ett skådespeleri som förvandlar både Wilson och Hayek till elaka karikatyrer på sig själva.

Källa

negativ

Klassificering av nyhetstexter

Sverige	Världen	Näringsliv	Sport
löntagare sossarna	president kongress	bolag redovisning	stafett skiathlon
ostlänken stambanor	brexit EU	aktier kurser	allsvenskan hemmaplan
ekholmen rattonykterhet	hertig sussex	handelsavtal protektionism	målskytt styrning

Forensisk lingvistik

Antalet mordutredningar som klarats upp på just detta sätt är för all del inte enormt, men växer stadigt. Samma tekniker används även (fast detaljerna är av lätt insedda skäl inte offentliga) för att få span på potentiella terrorister och pedofiler. Är det i själva verket Kent-Åke (68), som utger sig för att vara Lisa (13) på det ungdomliga diskussionsforumet?

AI för naturligt språk

Sentimentanalys

Marco Kuhlmann

Institutionen för datavetenskap

Sentimentanalys

Men den välanvända tropen och välbekanta strukturen till trots är ”Palm Springs” en riktig liten pärla, genomförd med både finesse och ett stort känslomässigt gehör. Det är ... en berättelse som vibrerar av hjärta och smartness under sin småfåniga exteriör.

Källa

positiv

Tyvärr är ”Bliss”, utöver det ganska vackra fotot, en enda röra. Den överlastade, men svårt undergestaltade, intrigen solkas av kass dialog och ett skådespeleri som förvandlar både Wilson och Hayek till elaka karikatyrer på sig själva.

Källa

negativ

Sentimentanalys

- **Sentimentanalys** i sin enklaste form försöker bestämma polariteten i en åsikt om t.ex. en film eller en produkt.
positiv/negativ, positiv/negativ/neutral
- Detta kan vara en förhållandevis lätt uppgift, då åsikter ofta kan kopplas till enstaka ord.
pärla, finess, vibrerar; röra, överlastade, elaka
- En enkel metod för sentimentanalys är därför att matcha orden i texten mot listor med positiva och negativa ord.

Utmaningar med sentimentanalys

- **Negationer och kontrafaktiska uttryck**

Det var inte illa.

Det är inte det värsta som kan hända.

Denna film kunde ha blivit en riktig höjdare – men så blev det inte.

- **Ironi och sarkasm**

Vad trevligt, ännu en hjärtvärmande romantisk komedi!

Skådespelarna är så otroligt roliga, de borde bli komiker.

Han är ju bra på det här. 😂

Aspektbaserad sentimentanalys

NEGATIV ASPEKT
Jag hatade deras fajitas,
men salladerna var jättegoda!
ASPEKT POSITIV

{fajitas: negativ, salladerna: positiv}

Liknande problem

- **Detektera subjektiva textpassager**

Att identifiera de delar av en text som uttrycker subjektiva uppfattningar eller spekulationer, snarare än fakta.

eng. subjectivity detection

- **Detektera ställningstaganden**

Att i en debatt avgöra vilken sida en debattör står för, t.ex. om hen är för eller emot ett lagförslag.

eng. stance classification

AI för naturligt språk

Textklassificering som maskininlärning

Marco Kuhlmann

Institutionen för datavetenskap

Textklassificering som maskininlärning



Textklassificering som maskininlärning

träning
träning

president
kongress

A

bolag
redovisning

B

stafett
skiathlon

C

brexit
EU

A

aktier
kurser

B

allsvenskan
hemmaplan

C

test
utvärdering

hertig
sussex

A

handelsavtal
protektionism

B

målskytt
styrning

C

A

B

A

Varifrån får vi annoterade datamängder?

- manuell annotering

exempel: taggning av nyhetsartiklar

- använda parallella, icke-språkliga signaler

exempel: emotikoner i twitterinlägg

- kombinera olika datamängder

exempel: anföranden i riksdagen + omröstningsresultat


AI för naturligt språk

Korrekthet

Marco Kuhlmann

Institutionen för datavetenskap

Utvärdering av textklassificerare



Korrekthet

Begreppet **korrekthet** (eng. *accuracy*) betecknar andelen av alla dokument i testmängden för vilka systemet predicerar rätt klass:

$$\text{korrekthet} = \frac{\text{antal korrekt klassificerade dokument}}{\text{totalt antal dokument}}$$

Korrektthet

Dokument	Guldstandard	Predicerad klass
stafett skiathlon	Sport	Sport
allsvenskan hemmaplan	Sport	Sport
målskytt styrning	Sport	Sport
kurs avgift	Sport	Näringsliv

korrektthet: $3/4 = 75\%$

Förväxlingsmatris

	klassificerare "positiv"	klassificerare "negativ"
guldstandard "positiv"	sanna positiva	falska negativa
guldstandard "negativ"	falska positiva	sanna negativa

Beräkna korrekthet utifrån förväxlingsmatrisen



	klassificerare "positiv"	klassificerare "negativ"
guldstandard "positiv"	sanna positiva	falska negativa
guldstandard "negativ"	falska positiva	sanna negativa

Korrekthet vid tre klasser

$$\frac{112}{133} \simeq 84\%$$

	A	B	C
A	58	6	1
B	5	11	2
C	0	7	43

AI för naturligt språk


Precision och täckning

Marco Kuhlmann

Institutionen för datavetenskap

Korrekthet kan vara missvisande

Är 80% korrekthet bra eller dåligt?



Precision och täckning (recall)

- **Precision** och **täckning** (eng. *recall*) ”zoomar in” på hur bra ett system är på att identifiera dokument med en specifik klass *c*.
- **Precision** med avseende på klass *c* svarar på frågan:
Hur många procent av de dokument för vilka systemet predicerar klass *c* tillhör denna klass enligt guldstandard?
- **Täckning** med avseende på klass *c* svarar på frågan:
För hur många procent av de dokument som enligt guldstandard tillhör klass *c* predicerar systemet att de har denna klass?

Precision med avseende på den positiva klassen



	klassificerare "positiv"	klassificerare "negativ"
guldstandard "positiv"	sanna positiva	falska negativa
guldstandard "negativ"	falska positiva	sanna negativa

Täckning med avseende på den positiva klassen



	klassificerare "positiv"	klassificerare "negativ"
guldstandard "positiv"	sanna positiva	falska negativa
guldstandard "negativ"	falska positiva	sanna negativa

Precision med avseende på klass B

$$\frac{11}{24} \approx 46\%$$

	A	B	C
A	58	6	1
B	5	11	2
C	0	7	43

Täckning med avseende på klass B

$$\frac{11}{18} \approx 61\%$$

	A	B	C
A	58	6	1
B	5	11	2
C	0	7	43

AI för naturligt språk

Fler utvärderingsmått

Marco Kuhlmann

Institutionen för datavetenskap

Utvärdering av klassificerare i scikit-learn

	precision	recall	f1-score	support	predicerad = guldstandard
C	0.63	0.04	0.07	671	
KD	0.70	0.02	0.03	821	
L	0.92	0.02	0.04	560	
M	0.36	0.68	0.47	1644	
MP	0.36	0.25	0.29	809	
S	0.46	0.84	0.59	2773	
SD	0.57	0.12	0.20	1060	
V	0.59	0.15	0.24	950	
accuracy			0.43	9288	
macro avg	0.57	0.26	0.24	9288	
weighted avg	0.52	0.43	0.34	9288	

Utvärdering av klassificerare i scikit-learn


	precision	recall	f1-score	support
C	0.63	0.04	0.07	671
KD	0.70	0.02	0.03	821
L	0.92	0.02	0.04	560
M	0.36	0.68	0.47	1644
MP	0.36	0.25	0.29	809
S	0.46	0.84	0.59	2773
SD	0.57	0.12	0.20	1060
V	0.59	0.15	0.24	950
accuracy			0.43	9288
macro avg	0.57	0.26	0.24	9288
weighted avg	0.52	0.43	0.34	9288

F1-måttet

F1-värdet med avseende på klass c är det harmoniska medelvärdet mellan precision och täckning med avseende på denna klass:

$$F1 = \frac{2 \cdot \text{precision} \cdot \text{täckning}}{\text{precision} + \text{täckning}}$$

F1-värdet



Utvärdering av klassificerare i scikit-learn

	precision	recall	f1-score	support
C	0.63	0.04	0.07	671
KD	0.70	0.02	0.03	821
L	0.92	0.02	0.04	560
M	0.36	0.68	0.47	1644
MP	0.36	0.25	0.29	809
S	0.46	0.84	0.59	2773
SD	0.57	0.12	0.20	1060
V	0.59	0.15	0.24	950
accuracy			0.43	9288
macro avg	0.57	0.26	0.24	9288
weighted avg	0.52	0.43	0.34	9288

Utvärdering av klassificerare i scikit-learn

	precision	recall	f1-score	support
C	0.63	0.04	0.07	671
KD	0.70	0.02	0.03	821
L	0.92	0.02	0.04	560
M	0.36	0.68	0.47	1644
MP	0.36	0.25	0.29	809
S	0.46	0.84	0.59	2773
SD	0.57	0.12	0.20	1060
V	0.59	0.15	0.24	950
accuracy			0.43	9288
macro avg	0.57	0.26	0.24	9288
weighted avg	0.52	0.43	0.34	9288

AI för naturligt språk


Generellt om utvärderingsmått

Marco Kuhlmann

Institutionen för datavetenskap

Tolkning av utvärderingsmåttet

Är 80% korrekthet bra eller dåligt?



Utvärderingsmått är relativa mått

- Utvärderingsmått är inga absoluta mått – det meningslöst att säga att 80% korrekthet är ”bra”.
- Utvärderingsmått kan endast användas för att jämföra en klassificerare med ett referensvärde, en **baseline**.

”Logistisk regression har 2 poäng högre korrekthet än Naive Bayes.”

- En enkel baseline är att predicera ett dokument klass genom att slumpa fram den enligt klassernas fördelning i träningsdatan.

Utvärdera = uppskatta generaliseringsförmåga

- Träningsmängd och testmängd ska ses som två av varandra oberoende stickprov från en population av dokument.
- Genom att mäta klassificerarens korrekthet m.fl. på testmängden uppskattar vi dess förmåga att generalisera.
under antagandet att framtida dokument kommer från samma population
- För att detta ska vara meningsfullt måste träningsmängd och testmängd vara disjunkta och ha samma fördelning av klasserna.

Statisk uppdelning

ursprunglig
datamängd



samma fördelning
i delmängderna




träning test

olika fördelningar
i delmängderna



träning test

Korsvalidering



AI för naturligt språk

Naive Bayes-klassificeraren


Marco Kuhlmann

Institutionen för datavetenskap

Naive Bayes

- **Naive Bayes-klassificeraren** är en enkel men förvånansvärt användbar klassificeringsalgoritm som bygger på Bayes' regel.
- Den kallas "naiv" eftersom den gör starka (orealistiska) antaganden om oberoende mellan sannolikheter.
- Naive Bayes-klassificeraren finns i flera olika versioner. Här behandlar vi det som kallas för "multinomial Naive Bayes".

Naive Bayes som sannolikhetsmodell



Bayes' rule

- För att klassificera ett dokument skulle vi vilja veta den betingade sannolikheten $P(\text{klass} | \text{ord})$.
- Naive Bayes-modellen innehåller dock endast de omvänt betingade sannolikheterna på formen $P(\text{ord} | \text{klass})$.
- För att konvertera mellan dessa två typer av sannolikheter kan vi använda **Bayes' regel**.

$$P(\text{klass} | \text{ord}) \propto P(\text{klass}) P(\text{ord} | \text{klass})$$

Bayes' regel



Thomas Bayes
(1702–1761)

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

Ingredienserna i en Naive Bayes-klassificerare

- C de fördefinierade klasserna, t.ex. {positiv, negativ}
- V de möjliga orden; modellens **vokabulär**
- $P(c)$ **klass sannolikheter** som svarar på frågan: ”Hur sannolikt är det att ett givet dokument tillhör klass c ?”
- $P(w|c)$ **ords sannolikheter** som svarar på frågan: ”Hur sannolikt är det att ett dokument med klass c innehåller ordet w ?”

Beslutsregeln i en Naive Bayes-klassificerare

antal ord i det dokument
som vi vill klassificera

$$\hat{c} = \arg \max_{c \in C} \left[P(c) \cdot \prod_{i=1}^n P(w_i | c) \right]$$

predicerad klass
för dokumentet

sannolikheten
för ordet w_i , givet klass c

AI för naturligt språk

Inlärningsalgoritmen för Naive Bayes

Marco Kuhlmann

Institutionen för datavetenskap

Att träna upp en Naive Bayes-klassificerare



$$P(c)$$

klassannolikheter

$$P(w|c)$$

ordsannolikheter

Maximum Likelihood Estimation (MLE)

- Standardmetoden för att skatta sannolikheter i en modell heter **Maximum Likelihood Estimation (MLE)**.
- När vi följer MLE-principen vill vi hitta de sannolikheter som maximerar sannolikheten för träningsdatamängden.
- För Naive Bayes-klassificeraren är MLE väldigt enkel: det enda vi behöver göra är att räkna dokument och ord.

Maximum Likelihood Estimation (MLE)

	Vanlig slant	Viktad slant								
datamängd	<table border="1"><thead><tr><th>krona</th><th>klave</th></tr></thead><tbody><tr><td>2</td><td>2</td></tr></tbody></table>	krona	klave	2	2	<table border="1"><thead><tr><th>krona</th><th>klave</th></tr></thead><tbody><tr><td>3</td><td>1</td></tr></tbody></table>	krona	klave	3	1
krona	klave									
2	2									
krona	klave									
3	1									
MLE-skattade sannolikheter	<table border="1"><tbody><tr><td>$\frac{1}{2}$</td><td>$\frac{1}{2}$</td></tr></tbody></table>	$\frac{1}{2}$	$\frac{1}{2}$	<table border="1"><tbody><tr><td>$\frac{3}{4}$</td><td>$\frac{1}{4}$</td></tr></tbody></table>	$\frac{3}{4}$	$\frac{1}{4}$				
$\frac{1}{2}$	$\frac{1}{2}$									
$\frac{3}{4}$	$\frac{1}{4}$									
datamängdens totala sannolikhet	$\left(\frac{1}{2}\right)^2 \cdot \left(\frac{1}{2}\right)^2 = \frac{16}{256}$	$\left(\frac{3}{4}\right)^3 \cdot \left(\frac{1}{4}\right)^1 = \frac{27}{256}$								

Maximum Likelihood Estimation (MLE)

	Vanlig slant	Viktad slant								
datamängd	<table border="1"><thead><tr><th>krona</th><th>klave</th></tr></thead><tbody><tr><td>2</td><td>2</td></tr></tbody></table>	krona	klave	2	2	<table border="1"><thead><tr><th>krona</th><th>klave</th></tr></thead><tbody><tr><td>3</td><td>1</td></tr></tbody></table>	krona	klave	3	1
krona	klave									
2	2									
krona	klave									
3	1									
icke-MLE sannolikheter	<table border="1"><tbody><tr><td>$\frac{3}{4}$</td><td>$\frac{1}{4}$</td></tr></tbody></table>	$\frac{3}{4}$	$\frac{1}{4}$	<table border="1"><tbody><tr><td>$\frac{1}{2}$</td><td>$\frac{1}{2}$</td></tr></tbody></table>	$\frac{1}{2}$	$\frac{1}{2}$				
$\frac{3}{4}$	$\frac{1}{4}$									
$\frac{1}{2}$	$\frac{1}{2}$									
datamängdens totala sannolikhet	$\left(\frac{3}{4}\right)^2 \cdot \left(\frac{1}{4}\right)^2 = \frac{9}{256}$ <p style="text-align: right;">16</p>	$\left(\frac{1}{2}\right)^3 \cdot \left(\frac{1}{2}\right)^1 = \frac{16}{256}$ <p style="text-align: right;">27</p>								

MLE för Naive Bayes

$\#(c)$ antal dokument med guldstandard-klass c

$\#(w, c)$ antal förekomster av ordet w i dokument med klass c

$$P(c) = \frac{\#(c)}{\sum_{x \in C} \#(x)}$$

$$P(w | c) = \frac{\#(w, c)}{\sum_{x \in V} \#(x, c)}$$

Sentimentanalys

Men den välanvända tropen och välbekanta strukturen till trots är ”Palm Springs” en riktig liten pärla, genomförd med både finesse och ett stort känslomässigt gehör. Det är ... en berättelse som vibrerar av hjärta och smartness under sin småfåniga exteriör.

39 token

positiv

Tyvärr är ”Bliss”, utöver det ganska vackra fotot, en enda röra. Den överlastade, men svårt undergestaltade, intrigen solkas av kass dialog och ett skådespeleri som förvandlar både Wilson och Hayek till elaka karikatyrer på sig själva.

36 token

negativ

Skattning av ordsannolikheter

Ord	Förekomster
en	2
karikatyrer	0
pärla	1
röra	0
vibrerar	1
...	

positiv

Ord	Förekomster
en	1
karikatyrer	1
pärla	0
röra	1
vibrerar	0
...	

negativ

Skattning av ordsannolikheter

Sannolikhet	Skattat värde
$P(\text{en} \text{pos})$	2/39
$P(\text{karikatyrrer} \text{pos})$	0/39
$P(\text{pärla} \text{pos})$	1/39
$P(\text{röra} \text{pos})$	0/39
$P(\text{vibrerar} \text{pos})$	1/39
...	
	positiv

Sannolikhet	Skattat värde
$P(\text{en} \text{neg})$	1/36
$P(\text{karikatyrrer} \text{neg})$	1/36
$P(\text{pärla} \text{neg})$	0/36
$P(\text{röra} \text{neg})$	1/36
$P(\text{vibrerar} \text{neg})$	0/36
...	
	negativ

AI för naturligt språk

Dokumentrepresentationer

Marco Kuhlmann


Institutionen för datavetenskap

Dokumentrepresentationer

- För att kunna träna och tillämpa en textklassificerare behöver vi representera dokument som tal.
- I Naive Bayes-klassificeraren representerar vi dokument genom att räkna antalet ordförekomster.
- Mera generellt så kommer vi att översätta dokument till listor av tal, som vi tolkar som vektorer.

nyckeln till artificiella neuronnet

Standardkedjan för textklassificering



Sentimentanalys

Men den välanvända tropen och välbekanta strukturen till trots är ”Palm Springs” en riktig liten pärla, genomförd med både finesse och ett stort känslomässigt gehör. Det är ... en berättelse som vibrerar av hjärta och smartness under sin småfåniga exteriör.

Källa

positiv

Tyvärr är ”Bliss”, utöver det ganska vackra fotot, en enda röra. Den överlastade, men svårt undergestaltade, intrigen solkas av kass dialog och ett skådespeleri som förvandlar både Wilson och Hayek till elaka karikatyrer på sig själva.

Källa

negativ

Bag-of-words

Ord	Förekomster
-----	-------------

en 2

karikatyror 0

pärlla 1

röra 0

vibrerar 1

...

positiv

Ord	Förekomster
-----	-------------

en 1

karikatyror 1

pärlla 0


röra 1

vibrerar 0

...

negativ

Bag-of-words



Tf-idf

Ord	tf-idf
-----	--------

en 0,60

karikatyrer 0,00

pärla 0,40

röra 0,00

vibrerar 0,40

...

positiv

Ord	tf-idf
-----	--------

en 0,30

karikatyrer 0,40

pärla 0,00

röra 0,40

vibrerar 0,00

...

negativ


AI för naturligt språk

Logistisk regression

Marco Kuhlmann

Institutionen för datavetenskap

Klassificering med ett linjärt neuronnät



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

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


Den logistiska modellen

- Den **logistiska modellen** utökar den generaliserade linjära modellen med en icke-linjär funktion f :

$$y = f(z) \quad \text{där} \quad z = \mathbf{x}W + \mathbf{b}$$

- Denna så kallade **softmax-funktion** transformerar de klassspecifika utvärdena till tal som kan tolkas som sannolikheter.

Logistisk regression



Softmax-funktionen


Softmax-funktionen transformerar alla invärden till icke-negativa tal och normaliserar värdena så att de summerar till 1:

$$\text{softmax}(\mathbf{z})[i] = \frac{\exp(\mathbf{z}[i])}{\sum_k \exp(\mathbf{z}[k])}$$

Diagram illustrating the Softmax function formula with annotations:

- exponentialfunktionen**: Points to the $\exp(\mathbf{z}[i])$ term in the numerator.
- invärde för klass i**: Points to the $\mathbf{z}[i]$ term inside the exponential function in the numerator.
- utvärde för klass i**: Points to the $[i]$ index in the $\text{softmax}(\mathbf{z})[i]$ expression.

Logistisk regression som neuronnät



Samma parametrar som ett linjärt neuronnät.

AI för naturligt språk

Inlärningsalgoritmen för logistisk regression


Marco Kuhlmann

Institutionen för datavetenskap

Att träna upp logistisk regression

- Att träna upp en logistisk modell innebär att sätta vikterna och baskonstanterna i den underliggande linjära modellen.
- Eftersom logistisk regression är en probabilistisk modell kan vi använda MLE-principen, precis som för Naive Bayes.
- Den här gången räcker det inte med att räkna – men vi kan använda gradientsökning!

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

Korsentropi

- Istället för att maximera sannolikheten av träningsmängden minimerar vi modellens **korsentropi** (eng. *cross-entropy*).

motsvarigheten till kvadratfel i linjär regression

- Korsentropifelet för ett träningsexempel (\mathbf{x}, y) är den negativa logaritmen av den sannolikhet som modellen tilldelar y .

formel: $-\log P(y|\mathbf{x})$

Korsentropi

$P(A x)$	$P(B x)$	guldstandard	felvärde
1,00	0,00	A	0,00
0,50	0,50	A	0,30
0,25	0,75	A	0,60
0,00	1,00	A	∞

Korsentropi

