

# Worte als Vektoren, Vektorräume, Normen

Katja Markert

Institut für Computerlinguistik  
Uni Heidelberg  
markert@cl.uni-heidelberg.de

May 6, 2019

- 1 Bisher: Assoziationsmaße für Kollokationen: Kookkurrenz, Signifikanztests, (P)PMI
- 2 Heute: Darstellung eines Wortes als Vektor der Assoziationsmaße zu anderen Wörtern: sparse embeddings
- 3 Heute: Wiederholung von Standardmathe (Vektorräume, Vektoroperationen, Normen und Metriken)

- 1 Worte als Vektoren
- 2 Kurze Wiederholung Vektoren und Vektoroperationen
- 3 Normen
- 4 Zusammenfassung

- 1 Worte als Vektoren
- 2 Kurze Wiederholung Vektoren und Vektoroperationen
- 3 Normen
- 4 Zusammenfassung

Bisher: Assoziationsmaß als Funktion *Assoc* von der Menge aller Bigramme zu  $\mathbb{R}$

Assoc	$assoc(w_1, w_2)$
$assoc_{bin}$	1, wenn mindestens einmal $w_1 w_2$ in Korpus, 0 sonst
$assoc_{freq}$	$f(w_1, w_2)$
$assoc_{cond}$	$p(w_2 w_1) = f(w_1, w_2)/f(w_1)$
$assoc_{pmi}$	$\log \frac{p(w_1, w_2)}{p(w_1) \cdot p(w_2)}$
$assoc_{ttest}$	$\frac{\bar{x} - \mu}{\sqrt{\frac{\sigma^2}{N}}}$
$assoc_{\chi^2}$	$\sum_{i,j} \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$

Implizit: Die benutzten Frequenzen und Wahrscheinlichkeiten beziehen sich auf die Relation  $rel_{bigram}$ . Beispiele:

- Binär: das Bigram  $w_1 w_2$  erscheint oder nicht
- Häufigkeit  $f(w_1, w_2)$  ist Häufigkeit des Bigrams  $w_1 w_2$
- ...

Bisher: Assoziationsmaß als Funktion  $Assoc$  von der Menge aller Bigramme zu  $\mathbb{R}$

Assoc	$assoc(w_1, w_2)$
$assoc_{bin}$	1, wenn mindestens einmal $w_1 w_2$ in Korpus, 0 sonst
$assoc_{freq}$	$f(w_1, w_2)$
$assoc_{cond}$	$p(w_2 w_1) = f(w_1, w_2)/f(w_1)$
$assoc_{pmi}$	$\log \frac{p(w_1, w_2)}{p(w_1) \cdot p(w_2)}$
$assoc_{ttest}$	$\frac{\bar{x} - \mu}{\sqrt{\frac{\sigma^2}{N}}}$
$assoc_{\chi^2}$	$\sum_{i,j} \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$

Implizit: Die benutzten Frequenzen und Wahrscheinlichkeiten beziehen sich auf die Relation  $rel_{bigram}$ . Beispiele:

- Binär: das Bigram  $w_1 w_2$  erscheint oder nicht
- Häufigkeit  $f(w_1, w_2)$  ist Häufigkeit des Bigrams  $w_1 w_2$
- ...

Man kann dies auf andere Relationen erweitern. Beispiel:  $rel_{win5}$

- Binär:  $w_1$  und  $w_2$  erscheinen in einem Fenster von 5 Tokens zusammen oder nicht
- Häufigkeit  $f(w_1, w_2)$  ist Häufigkeit des gemeinsamen Vorkommens in einem 5-Token Fenster
- ...

Assoc	$assoc(w_1, w_2)$
$assoc_{bin}$	1, wenn mindestens einmal $w_1, w_2$ in Korpus, 0 sonst
$assoc_{freq}$	$f(w_1, w_2)$
$assoc_{cond}$	$p(w_2 w_1) = f(w_1, w_2)/f(w_1)$
$assoc_{pmi}$	$\log \frac{p(w_1, w_2)}{p(w_1) \cdot p(w_2)}$
$assoc_{ttest}$	$\frac{\bar{x} - \mu}{\sqrt{\frac{\sigma^2}{N}}}$
$assoc_{\chi^2}$	$\sum_{i,j} \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$

$rel_{bigram}$  ist eine geordnete Version von  $rel_{win1}$

Wir wählen eine Relation  $rel$  und ein Assoziationsmaß  $assoc$ . Wir können nun ein Wort  $w$  auch als Vektor der Assoziationsmaße zu anderen Wörtern  $w_1, \dots, w_n$  eines Vokabulars  $Voc$  darstellen.

$$\vec{w} = (assoc(w, w_1), assoc(w, w_2), assoc(w, w_3) \dots, assoc(w, w_n))$$

Hiermit haben wir ein embedding von  $w$ , da wir  $w$  nun einen Vektor aus  $\mathbb{R}^n$  zugewiesen haben!



Korpus BNC, Zielwort  $w$ ,  $V = \{species, computer, animal\}$ ,  $rel_{win10}$   
(window 5 to the right and 5 to left of  $w$ ),  $A_{freq} = assoc_{freq}$

$\vec{cat} = (A_{freq}(cat, species), A_{freq}(cat, computer), A_{freq}(cat, animal)) =$   
 $(59, 5, 304)$

$\vec{carnivore} =$   
 $(A_{freq}(carnivore, species), A_{freq}(carnivore, computer), A_{freq}(carnivore, animal)) =$   
 $(21, 1, 21)$

$\vec{airport} =$   
 $(A_{freq}(airport, species), A_{freq}(airport, computer), A_{freq}(airport, animal)) =$   
 $(4, 12, 2)$

Solange wir für alle Vektordarstellungen das gleiche Vokabular, das gleiche Assoziationsmaß sowie die gleiche Relation nehmen, sind die embeddings verschiedener Wörter vergleichbar (da in den gleichen Vektorraum eingebettet).

Matrixschreibweise (mit Vokabular in Spalten):

	<i>species</i>	<i>computer</i>	<i>animal</i>
<i>cat</i>	59	5	304
<i>carnivore</i>	21	1	21
<i>feline</i>	2	0	5
<i>airport</i>	4	12	2

Hierbei immer implizit: Assoziationsmaß sowie Relation!

- Vektoren und Matrizen: Gesamte lineare Algebra steht zur Verfügung
- Insbesondere: Wir können die Abstände bzw Ähnlichkeiten zwischen zwei Wörtern als die Distanz der beiden im Vektorraum messen!

	<i>species</i>	<i>computer</i>	<i>animal</i>
<i>cat</i>	59	5	304
<i>carnivore</i>	21	1	21
<i>feline</i>	2	0	5
<i>airport</i>	4	12	2

- Man sieht die ähnlicheren Wortpaare sind in den gleichen Vokabulardimensionen “stark” bzw schwach
- Wenn man unbedacht vorgeht, dann könnte die Ähnlichkeit fälschlicherweise von der Worthäufigkeit (= Vektorlänge) abhängen!
- Die Matrix ist im allgemeinen hochdimensional und “sparse” (siehe Matrix in Übungsblatt 1)

- Wie wähle ich das Vokabular? Oft die häufigsten  $n$  Unigramme ohne Funktionswörter. Warum?
- Wie wähle ich die Relation? (Siehe ECL)
- Was für ein Assoziationsmaß wähle ich? (Diskutiert in vorherigen Vorlesungen)

Die gleiche Matrix mit  $assoc_{bin}$ :

	<i>species</i>	<i>computer</i>	<i>animal</i>
<i>cat</i>	1	1	1
<i>carnivore</i>	1	1	1
<i>feline</i>	1	0	1
<i>airport</i>	1	1	1

- Wie bekomme ich einfach die Matrix in (P)PMI? (ECL, Wiederholung nächstes Mal)
- Wie berechne ich am besten die Vektorenähnlichkeit: jetzt!

- 1 Worte als Vektoren
- 2 Kurze Wiederholung Vektoren und Vektoroperationen**
- 3 Normen
- 4 Zusammenfassung

# (Reeller) Vektorraum: Definition

Es sei  $V$  eine Menge,  $\oplus : V \times V \rightarrow V$  eine innere zweistellige Verknüpfung (Vektoraddition) und  $\odot : \mathbb{R} \times V \rightarrow V$  eine äußere zweistellige Verknüpfung, genannt Skalarmultiplikation. Man nennt  $(V, \oplus, \odot)$  einen **reellen Vektorraum**, wenn gilt für alle  $\alpha, \beta \in \mathbb{R}$  und  $u, v, w \in V$

- 1  $u \oplus (v \oplus w) = (u \oplus v) \oplus w$  (Assoziativgesetz)
- 2 Existenz eines neutralen Elements (Nullvektors)  $0_V \in V$  mit  $v \oplus 0_V = 0_V \oplus v = v$
- 3 Existenz eines zu  $v \in V$  inversen Elements  $-v \in V$  mit  $v \oplus (-v) = (-v) \oplus v = 0_V$
- 4  $v \oplus u = u \oplus v$  (Kommutativgesetz)

sowie

- 1  $\alpha \odot (u \oplus v) = (\alpha \odot u) \oplus (\alpha \odot v)$
- 2  $(\alpha + \beta) \odot v = (\alpha \odot v) \oplus (\beta \odot v)$
- 3  $(\alpha \cdot \beta) \odot v = \alpha \odot (\beta \odot v)$
- 4  $1 \odot v = v$



Wir werden von nun an  $\oplus$  einfach als  $+$  schreiben, obwohl es sich hier um eine Vektoraddition handelt. Ebenso  $\odot$  als  $\cdot$ .

Je nach Ambiguität schreiben wir Vektoren auch mit einem Pfeil  $\vec{v}$ .

Der altbekannte  $\mathbb{R}^n := \{(v_1, \dots, v_n) \mid v_1, \dots, v_n \in \mathbb{R}\}$  als Menge aller  $n$ -Tupel über  $\mathbb{R}$  bildet einen reellen Vektorraum, wenn man definiert:

- 1 Vektoraddition zwischen

$$u = (u_1, u_2, \dots, u_n), v = (v_1, v_2, \dots, v_n) \in \mathbb{R}^n: u + v = (u_1 + v_1, u_2 + v_2, \dots, u_n + v_n)$$

- 2 Skalarmultiplikation zwischen  $\alpha \in \mathbb{R}$  und

$$v = (v_1, v_2, \dots, v_n) \in \mathbb{R}^n: \alpha \cdot v = \alpha \cdot (v_1, v_2, \dots, v_n) := (\alpha v_1, \alpha v_2, \dots, \alpha v_n)$$

Er wird auch **Koordinatenraum** genannt (mit elementweiser Addition und Skalarmultiplikation).

- 1 Neutrales Element (Nullvektor) =  $(0, \dots, 0)$
- 2 Inverses Element zu  $v = (v_1, \dots, v_n)$  ist  $v = (-v_1, \dots, -v_n)$
- 3 Beispiel in der euklidischen Ebene  $\mathbb{R}^2$




Bild von Martin Thoma, CC BY 3.0,  
<https://commons.wikimedia.org/w/index.php?curid=21388478>

- **Komponenten** eines Vektors:  $i$ -te Komponente:  $v_1, \dots, v_i, \dots, v_n$
- Anzahl der Komponenten = **Vektordimensionalität**
- Man kann Vektoren auch vertikal schreiben:

$$v = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix} \quad (1)$$

- Andere reelle Vektorräume: Matrizenräume (nächste Woche), reelle Polynome ...

- 1 Worte als Vektoren
- 2 Kurze Wiederholung Vektoren und Vektoroperationen
- 3 Normen**
- 4 Zusammenfassung

## Idee

Ordne einem Element eines Vektorraums eine Größe zu.

Eine **Norm** ist definiert als eine Abbildung:

$$\|\cdot\|: V \rightarrow \mathbb{R}_0^+, v \mapsto \|v\|$$

mit den folgenden Eigenschaften für alle  $v, w \in V$  und  $\alpha \in \mathbb{R}$ :

- 1 Definitheit:  $\|v\| = 0 \Leftrightarrow v = 0$
- 2 absolute Homogenität:  $\|\alpha \cdot v\| = |\alpha| \cdot \|v\|$
- 3 Subadditivität oder Dreiecksungleichung:  $\|v + w\| \leq \|v\| + \|w\|$

①  $\| -v \| = | -1 | \cdot \| v \| = \| v \|$


② Aus Dreiecksungleichung:

$\| \vec{0} \| = \| v + (-v) \| \leq \| v \| + \| -v \| = 2\| v \|$  und damit: Normen sind immer nicht-negativ

Die **euklidische Norm** oder  $L_2$ -Norm:

$$\|v\|_2 := \sqrt{\sum_{i=1}^n v_i^2}$$

- Wir überlegen uns, warum dies die Normaxiome erfüllt (Tafel)
- Beispiel im  $\mathbb{R}^3$ :  $\|(1, -2, 1)\|_2 = \sqrt{1^2 + 2^2 + 1^2} = \sqrt{6}$
- Offene Einheitskugel: *Menge aller  $v$  mit  $\|v\|_2 < 1$*






## Maximumsnorm oder Unendlich-Norm oder Tschebyschev-Norm

$$\|v\|_{\infty} := \max_{i=1, \dots, n} |v_i|$$


- Wir überlegen uns, warum dies die Normaxiome erfüllt (Tafel)
- Beispiel im  $\mathbb{R}^3$ :  $\|(1, -2, 1)\|_{\infty} = 2$
- Offene Einheitskugel: Menge aller  $v$  mit  $\|v\|_{\infty} < 1$



Summennorm oder  $L_1$ -Norm:

$$\|v\|_1 = \sum_{i=1}^n |v_i|$$

- Wir überlegen uns, warum dies die Normaxiome erfüllt (Tafel)
- Beispiel im  $\mathbb{R}^3$ :  $\|(1, -2, 1)\|_1 = 4$
- Offene Einheitskugel: Menge aller  $v$  mit  $\|v\|_1 < 1$



(a)

- Normierung von Vektoren, um Längeneffekte zu vermeiden (jetzt)
- Induzierung von Metriken (jetzt)
- Normen in objective functions beim Maschinellen Lernen, als Fehlerfunktion (Vorlesung Statistische Methoden)
- Normen in objective functions als Regularisierung, um “Overfitting” zu Trainingsdaten zu minimieren (Vorlesung “Statistische Methoden”)

Gegeben sei ein normierter Vektorraum und  $v$  ein Vektor, der nicht der Nullvektor ist. Wir nennen den Vektor  $\frac{v}{\|v\|}$  einen **Einheitsvektor**, denn es gilt:

$$\left\| \frac{v}{\|v\|} \right\| = \left| \frac{1}{\|v\|} \right| \cdot \|v\| = 1$$

Beispiel im  $\mathbb{R}^3$  Vektor  $\vec{v} = (1, -2, 1)$

- 1 Mit der euklidischen Norm gilt  $\|(1, -2, 1)\|_2 = \sqrt{6}$  und damit der von  $\vec{v}$  abgeleitete Einheitsvektor  $\vec{v}_e = \frac{\vec{v}}{\|\vec{v}\|_2} = \left(\frac{1}{\sqrt{6}}, \frac{-2}{\sqrt{6}}, \frac{1}{\sqrt{6}}\right)$  und damit

$$\|\vec{v}_e\|_2 = \sqrt{\left(\frac{1}{\sqrt{6}}\right)^2 + \left(\frac{-2}{\sqrt{6}}\right)^2 + \left(\frac{1}{\sqrt{6}}\right)^2} = \sqrt{1/6 + 4/6 + 1/6} = 1$$

- 2 Mit der Maximumsnorm gilt  $\|(1, -2, 1)\|_\infty = 2$  und damit ist der von  $\vec{v}$  abgeleitete Einheitsvektor  $\vec{v}_e =$

$$\frac{\vec{v}}{\|\vec{v}\|_\infty} = \left(\frac{1}{2}, \frac{-2}{2}, \frac{1}{2}\right) = (0.5, -1, 0.5). \text{ Damit ist } \|\vec{v}_e\|_\infty = 1$$

- 1 Worte als Vektoren
- 2 Kurze Wiederholung Vektoren und Vektoroperationen
- 3 Normen
- 4 Zusammenfassung**

- Wir können Worte als Vektoren von Assoziationsmaßen zu anderen Wörtern auffassen  $\rightarrow$  Embeddings
- Lineare Algebra: Vektorräume und Vektoroperationen
- Normen in Vektorräumen erlauben uns, Vektoren eine Größe zuzuordnen
- Wir können Vektoren normieren

- Jurafsky und Martin, Edition II: Kapitel 20
- Gerd Fischer: Lineare Algebra. Eine Einführung für Studienanfänger
- Serie von Videos von 3Blue1Brown. Startet hier:  
`https://www.youtube.com/watch?v=fNk\_zzaMoSs&list=PLZHQObOWTQDPD3MizzM2xVFitg`
- Übungsblatt 1: Aufgabe 2