

Dokumentdistanz

Übungen

Gross- und Kleinschreibung sowie Satzzeichen sind nicht zu berücksichtigen.

Aufgabe 1

Bestimmen Sie die Dokumentdistanz der Texte:

- ▶ „Die Katze jagt die Maus.“
- ▶ „Die Maus flieht vor der Katze.“

Aufgabe 1

Wort	d_1	d_2
der	0	1
die	2	1
flieht	0	1
jagt	1	0
katze	1	1
maus	1	1
vor	0	1

$$\text{dist}(d_1, d_2) = \arccos \frac{d_1 \cdot d_2}{|d_1| \cdot |d_2|} = \arccos \frac{4}{\sqrt{7} \cdot \sqrt{6}} = 51.89^\circ$$

Aufgabe 2

Jemand sucht nach einem Dokument, das möglichst gut mit den Begriffen

Dokumente, Distanz, Text

übereinstimmt. Welches der folgenden Dokumente müsste eine Suchmaschine zuerst präsentieren, wenn sie den Dokumentwinkel als Ähnlichkeitsmass verwendet?

- (a) „Er hatte keine Distanz zu seinem Text.“
- (b) „Den Text speichert er im Ordner für Dokumente.“

Aufgabe 2

Wort	d_1	d_2
distanz	1	1
dokumente	1	0
er	0	1
hatte	0	1
keine	0	1
seinem	0	1
text	1	1
zu	0	1

$$\text{dist}(d_1, d_2) = \arccos \frac{d_1 \cdot d_2}{|d_1| \cdot |d_2|} = \arccos \frac{2}{\sqrt{3} \cdot \sqrt{7}} = 64.12^\circ$$

Wort	d_1	d_3
den	0	1
distanz	1	0
dokumente	1	1
er	0	1
für	0	1
im	0	1
ordner	0	1
speichert	0	1
text	1	1

$$\text{dist}(d_1, d_3) = \arccos \frac{d_1 \cdot d_3}{|d_1| \cdot |d_3|} = \arccos \frac{2}{\sqrt{3} \cdot \sqrt{8}} = 65.91^\circ$$

Dokument 1 liegt näher bei den Suchbegriffen als Dokument 2.

Aufgabe 3

Wie verändert sich die Dokumentdistanz zwischen zwei Dokumenten, wenn man in einem der Dokumente willkürlich jedes Wort verdoppelt?

- (a) Die Dokumentdistanz wird grösser.
- (b) Die Dokumentdistanz wird kleiner.
- (c) Die Dokumentdistanz bleibt gleich.

Aufgabe 3

Die Dokumentdistanz bleibt gleich.

Aufgabe 4

Nennen Sie drei Anwendungsgebiete für die Dokumentdistanz.

Aufgabe 4

- ▶ Auffinden von Dokumenten (Datenbanken, Internet)
- ▶ Erkennung von Plagiaten
- ▶ automatische Klassifikation von Dokumenten