


Das Erkennen bibliographischer Dubletten

Dr. Harald Jele


harald.jele@uni-klu.ac.at

Universität Klagenfurt




Kontext des Projekts

- Phase 2: Integration der Datensätze des ISIS-Bibliothekssystem der IFF-Fakultät der Uni Klagenfurt (Schottenfeldgasse, 1090 Wien) in das Verbundsystem. Ca. 10.000 Titeldatensätze



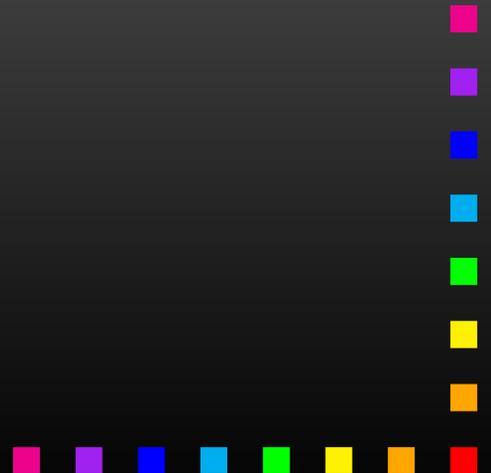
Kontext des Projekts

- Phase 2: Integration der Datensätze des ISIS-Bibliothekssystems der IFF-Fakultät der Uni Klagenfurt (Schottenfeldgasse, 1090 Wien) in das Verbundsystem. Ca. 10.000 Titeldatensätze
- Phase 1: Titeldublette = gleiche ISBN + gleiches Jahr + gleiche Auflage (abgeschlossen 2005, ca. 6.300 Titeldatensätze + Items + Holdings)




Prinzipien, die dabei verfolgt werden (1):

- Datensätze sind sich ähnlich oder gleich, wenn auch deren „Bestandteile“ sich ähnlich oder gleich sind (Kategorien, Begriffe, Silben, Zeichen)




Prinzipien, die dabei verfolgt werden (1):

- Datensätze sind sich ähnlich oder gleich, wenn auch deren „Bestandteile“ sich ähnlich oder gleich sind (Kategorien, Begriffe, Silben, Zeichen)
- unterschiedliche Regeln zur Katalogisierung bzw. die Auslegung dieser kann durch eine Reduzierung von Inhalten ausgeglichen werden (Normalisierung)




Prinzipien, die dabei verfolgt werden (2):

- nicht alle Datensätze einer beliebigen Menge sind gleich behandelbar (Vorsortierung ist sinnvoll bzw. notwendig)




Prinzipien, die dabei verfolgt werden (2):

- nicht alle Datensätze einer beliebigen Menge sind gleich behandelbar (Vorsortierung ist sinnvoll bzw. notwendig)
- Datenelemente, die nicht vorhanden sind, können nicht berechnet – aber als gleich angenommen – werden.
(Claudia: Die Leere Menge ist immer wahr)




Ansätze, die konkret realisiert wurden:

- Berechnung des Jaccard-Koeffizienten (häufig auch bei Plagiate-Software anzutreffen)




Ansätze, die konkret realisiert wurden:

- Berechnung des Jaccard-Koeffizienten (häufig auch bei Plagiate-Software anzutreffen)
- euklidische Distanz von Zeichenketten (math. Standard-Methode seit den 70er-Jahren, gut dokumentiert)




Ansätze, die konkret realisiert wurden:

- Berechnung des Jaccard-Koeffizienten (häufig auch bei Plagiate-Software anzutreffen)
- euklidische Distanz von Zeichenketten (math. Standard-Methode seit den 70er-Jahren, gut dokumentiert)
- Methode des KOBV: Euklidische Distanz gewichtet (Ergebnisse überprüfbar)




Vorgehensweise, bei allen drei Ansätzen gleich (1):

- Entladen der Datensätze aus Aleph und ISIS sowie Selektion der zu vergleichenden Kategorien: 100, 200, 331, 403 (Ausgabebez.), 410 (Erscheinungsorte), 412 (Verleger), 425 (Erscheinungsjahr), 433 (Umfangsangabe), 540 (ISBN)




Vorgehensweise, bei allen drei Ansätzen gleich (2):

- Laden der Daten in eine externe Datenbank




Vorgehensweise, bei allen drei Ansätzen gleich (2):

- Laden der Daten in eine externe Datenbank
- Normalisierung der Daten nach den Vorschlägen von Beate Rusch (KOBV)



Vorgehensweise, bei allen drei Ansätzen gleich (2):

- Laden der Daten in eine externe Datenbank
- Normalisierung der Daten nach den Vorschlägen von Beate Rusch (KOBV)
- Berechnung




Vorgehensweise, bei allen drei Ansätzen gleich (2):

- Laden der Daten in eine externe Datenbank
- Normalisierung der Daten nach den Vorschlägen von Beate Rusch (KOBV)
- Berechnung
- Ergebnisse in eine Ergebnistabelle zur weiteren Interpretation



Die wesentlichsten Schritte bei der Normalisierung (1):

- Umsetzen in US-ASCII-7-bit Großbuchstaben




Die wesentlichsten Schritte bei der Normalisierung (1):

- Umsetzen in `US-ASCII-7-bit` Großbuchstaben
- Löschen von Diakritika, Akzenten, Sonderzeichen, Steuerzeichen (wie z.B. die entsprechenden Stoppwortzeichen) sowie sämtlicher Zeichensatzzeichen, die außerhalb des definierten Zeichensatzes von `ASCII-7-bit` liegen




Die wesentlichsten Schritte bei der Normalisierung (1):

- Umsetzen in `US-ASCII-7-bit` Großbuchstaben
- Löschen von Diakritika, Akzenten, Sonderzeichen, Steuerzeichen (wie z.B. die entsprechenden Stoppwortzeichen) sowie sämtlicher Zeichensatzzeichen, die außerhalb des definierten Zeichensatzes von `ASCII-7-bit` liegen
- Umsetzen der deutschen Umlaute sowie des ß nach `AE, OE, UE, SS`




Die wesentlichsten Schritte bei der Normalisierung (2):

- Entfernen doppelter Leerzeichen (Blanks)



Die wesentlichsten Schritte bei der Normalisierung (2):

- Entfernen doppelter Leerzeichen (Blanks)
- Löschen der führenden sowie der abschließenden Leerzeichen




Die wesentlichsten Schritte bei der Normalisierung (2):

- Entfernen doppelter Leerzeichen (Blanks)
- Löschen der führenden sowie der abschließenden Leerzeichen
- Trunkierung der Feldeinträge an der feldspezifisch sinnvollen Stelle (z.B. bei Personennamen hinter dem ersten Buchstaben des zweiten Vornamens und bei bei Erscheinungsorten nach dem fünften Zeichen des ersten Wortes)



Die wesentlichsten Schritte bei der Normalisierung (3):


- Entfernen recherchierter Informationen, die Daten zur katalogisierenden Vorlage ergänzt und dazu entsprechend den angewandten Katalogisierungsregeln in eckigen Klammern hinzugefügt wurden



Beispiele zur Normalisierung (1):

- Kat 100:

Berendt, Hans A. → BERENDT HANS A
Huizinger, Franz Ernst »von« →
HUIZINGER FRANZ E



Beispiele zur Normalisierung (1):

- Kat 100:

Berendt, Hans A. → BERENDT HANS A
Huizinger, Franz Ernst »von« →
HUIZINGER FRANZ E


- Kat 200:

Zentrum für Umfragen, Methoden und
Analysen <Mannheim> → ZENTRUM FUER
UMFRAGEN METHODEN UND ANALYSEN
MANNHEIM



Beispiele zur Normalisierung (2):

- Kat 403:
Ausgabe 2001 → 2001
2., vollst. durchgesehene und
überarb. Aufl. → 2



Beispiele zur Normalisierung (2):

- Kat 403:
Ausgabe 2001 → 2001
2., vollst. durchgesehene und
überarb. Aufl. → 2
- Kat 410:
Frankfurt am Main [u.a.] → FRANK
München → MUENC




Beispiele zur Normalisierung (3):

- Kat 425:

2000 [erschiene] 1999 → 2000

[19]56 → 56



Beispiele zur Normalisierung (3):

- Kat 425:

2000 [erschiene] 1999 → 2000
[19]56 → 56

- Kat 433:


211 S., [21] Bl. → 211

XVI, 123 S. : Ill., graph. Darst.,
Kt. → 123




Ngramme als kleinste Einheit zur Berechnung der Ähnlichkeit:

- Trigramme werden in den meisten Verfahren bevorzugt gegenüber 2- oder 4-Grammen




Ngramme als kleinste Einheit zur Berechnung der Ähnlichkeit:

- Trigramme werden in den meisten Verfahren bevorzugt gegenüber 2- oder 4-Grammen
- Ähnlichkeit von Trigrammen → Ähnlichkeit der repräsentierten Zeichenketten



Bildung der Trigramme (1):


- Begriffe werden sequentiell zu Einheiten von jeweils drei Schriftzeichen zerlegt, wobei das jeweils letzte Zeichen eines Trigramms am Beginn des nächsten wiederholt wird.



Bildung der Trigramme (2):

- Bauernmarkt:

$$\vec{A} = \{ _ba, bau, aue, uer, ern, rnm, nma, mar, ark, rkt, kt_ \}$$




Bildung der Trigramme (2):

- Bauernmarkt:

$$\vec{A} = \{ _ba, bau, aue, uer, ern, rnm, nma, mar, ark, rkt, kt_ \}$$


- Marktbauern:

$$\vec{B} = \{ _ma, mar, ark, rkt, ktb, tba, bau, aue, uer, ern, rn_ \}$$



Das Jaccard-Maß (1):

- ist das Verhältnis der Skalarprodukte der beiden Zeichenvektoren




Das Jaccard-Maß (1):

- ist das Verhältnis der Skalarprodukte der beiden Zeichenvektoren
- das Skalarprodukt wird gebildet als

$$w_i \cdot q = \sum_{k=1}^n w_{i,k} q_k$$


in unserem Fall ist $w = \vec{A}$ und $q = \vec{B}$ zu verstehen



Das Jaccard-Maß (2):

- das Verhältnis der Skalarprodukte ist demnach

$$s_j(w_i, q) = \frac{\sum_{k=1}^n w_{i,k} q_k}{\sum_{k=1}^n w_{i,k} + \sum_{k=1}^n q_k - \sum_{k=1}^n w_{i,k} q_k}$$



Das Jaccard-Maß (3):

- für Vektoren, die mit den Werten 0 und 1 gewichtet werden (ein Trigramm kommt in beiden Zeichenketten vor – oder eben nicht) vereinfacht sich diese Darstellung auf folgende Gleichung:


$$\text{Jaccard-Maß} = \frac{\text{Schnittmenge}}{\text{Vereinigungsmenge}}$$

(=Wert zwischen 0 und 1)



Das Jaccard-Maß (4):

- nachdem das Jaccard-Maß Werte zwischen 0 und 1 annimmt, muss festgelegt werden, ab welchem Schwellenwert zwei miteinander verglichene Datensätze als ähnlich (oder ident) angesehen werden




Das Jaccard-Maß (4):

- nachdem das Jaccard-Maß Werte zwischen 0 und 1 annimmt, muss festgelegt werden, ab welchem Schwellenwert zwei miteinander verglichene Datensätze als ähnlich (oder ident) angesehen werden
- dafür liegen in der Literatur zur Berechnung bibliographischer Daten keine relevanten Ergebnisse vor (bzw. konnten keine gefunden werden). Für unsere Vorgehensweise wurde ein Wert zwischen 0.7 und 0.8 angenommen bzw. empirisch ermittelt


Der euklidische Abstand (1):

- wird gebildet als die Vektordifferenz zweier Vektoren, die das Vorkommen jener Trigramme abbilden, die in den beiden zu vergleichenden Zeichenketten vorhanden sind




Der euklidische Abstand (2):

- $\vec{A}_{S_1} = \{bau, aue, uer, ern, rnm, nma, mar, ark, rkt\}$



Der euklidische Abstand (2):

- $\vec{A}_{S_1} = \{bau, aue, uer, ern, rnm, nma, mar, ark, rkt\}$
- $\vec{A}_{S_2} = \{mar, ark, rkt, ktb, tba, bau, aue, uer, ern\}$



Der euklidische Abstand (2):


- $\vec{A}_{S1} = \{bau, aue, uer, ern, rnm, nma, mar, ark, rkt\}$
- $\vec{A}_{S2} = \{mar, ark, rkt, ktb, tba, bau, aue, uer, ern\}$
- steht für Bauernmarkt und Marktbauern



Der euklidische Abstand (3):

- die Differenz ist


$$\begin{aligned}\|\vec{D}\| &= \vec{A}_{S1} - \vec{A}_{S2} \\ &= \{rnm, nma, ktb, tba\} \\ &= \sqrt{1^2 + 1^2 + 1^2 + 1^2} = 2\end{aligned}$$



Der euklidische Abstand (4):

- zum Abstand hinzu kommt die empirische Ermittlung eines Schwellenwerts (T), über dem zwei miteinander zu vergleichende Zeichenketten nicht mehr als ähnlich angesehen werden

$$T = 2.486 + 0.025 * n$$



Der euklidische Abstand (4):


- zum Abstand hinzu kommt die empirische Ermittlung eines Schwellenwerts (T), über dem zwei miteinander zu vergleichende Zeichenketten nicht mehr als ähnlich angesehen werden

$$T = 2.486 + 0.025 * n$$

- wobei n die Anzahl der zu vergleichenden Teilstrings in der Vereinigungsmenge beider Vektoren darstellt Hylton (1996, S.47)


Die Methode des KOBV (1):

- bei diesem Verfahren wird die euklidische Distanz berechnet



Die Methode des KOBV (1):

- bei diesem Verfahren wird die euklidische Distanz berechnet
- diese wird auf eine Skala von 0 bis 1 transformiert



Die Methode des KOBV (1):

- bei diesem Verfahren wird die euklidische Distanz berechnet
- diese wird auf eine Skala von 0 bis 1 transformiert
- jede Kategorie wird gesondert verrechnet und gewichtet – und zwar positiv als auch negativ




Die Methode des KOBV (1):

- bei diesem Verfahren wird die euklidische Distanz berechnet
- diese wird auf eine Skala von 0 bis 1 transformiert
- jede Kategorie wird gesondert verrechnet und gewichtet – und zwar positiv als auch negativ
- zur Entscheidung, wie eine Kategorie gewichtet wird, gilt der Wert 0.8 als Schwellenwert




Die Methode des KOBV (2):

- wird bei der Berechnung der Schwellenwert erreicht oder überschritten, wird die Kategorie pos. gewichtet (anderenfalls negativ)




Die Methode des KOBV (2):

- wird bei der Berechnung der Schwellenwert erreicht oder überschritten, wird die Kategorie pos. gewichtet (anderenfalls negativ)
- zwei Datensätze gelten als gleich, wenn die Summe aller pos. Werte ≥ 0.5 und zugleich die Summe aller neg. Werte ≤ 0.3 ist




Gewichtungen im KOBV

Kategorie	pos. Gewichtung	neg. Gewichtung
Personenname	30	50
Körperschaftsname	30	50
Sachtitel	70	70
Standardnummer (z.B. ISBN)	70	60
Erscheinungsjahr	30	60
Erscheinungsorte	20	30
Verleger/in	20	20
Ausgabe- bezeichnung	30	60
Umfangsangabe	20	40



Prinzip der Datensatzabfrage (1)

- Ausgangspunkt einer Abfrage ist, dass nicht jeder Datensatz mit jedem anderen verglichen werden muss. Das dauert zulange und bringt ein zu großes Übermaß an Berechnungen, die eigentlich nicht notwendig sind



Prinzip der Datensatzabfrage (2)

- daher wird die kleinere Menge an Datensätzen als Anfragemenge genommen und mit dem ersten Begriff aus dem Autorenfeld (=meist wohl ein Teil des Familiennamens) eine Query in der Abfragemenge (=die größere Menge) getätigt




Prinzip der Datensatzabfrage (2)

- daher wird die kleinere Menge an Datensätzen als Anfragemenge genommen und mit dem ersten Begriff aus dem Autorenfeld (=meist wohl ein Teil des Familiennamens) eine Query in der Abfragemenge (=die größere Menge) getätigt
- alle Datensätze, die sich durch diese Query qualifizieren werden mit dem Anfragedatensatz verglichen


Prinzip der Datensatzabfrage (3)

- sollte ein Datensatz keinen Inhalt in Kat. 100 haben, wird der erste Begriff aus Kat. 331, der kein Stoppwort ist, zur Abfrage herangezogen




Struktur/Inhalte der Ergebnistabelle (1)

- Begriff, der zur Query herangezogen wurde




Struktur/Inhalte der Ergebnistabelle (1)

- Begriff, der zur Query herangezogen wurde
- AC-Nummern beider Datensätze




Struktur/Inhalte der Ergebnistabelle (1)

- Begriff, der zur Query herangezogen wurde
- AC-Nummern beider Datensätze
- Jaccard-Maß, nur pos. gewichtet



Struktur/Inhalte der Ergebnistabelle (1)

- Begriff, der zur Query herangezogen wurde
- AC-Nummern beider Datensätze
- Jaccard-Maß, nur pos. gewichtet
- Euklidischer Abstand, nur pos.




Struktur/Inhalte der Ergebnistabelle (1)

- Begriff, der zur Query herangezogen wurde
- AC-Nummern beider Datensätze
- Jaccard-Maß, nur pos. gewichtet
- Euklidischer Abstand, nur pos.
- errechneter Schwellenwert zum euklid. Abstand




Struktur/Inhalte der Ergebnistabelle (2)

- KOBV-Wert, nur pos. gewichtet




Struktur/Inhalte der Ergebnistabelle (2)

- KOBV-Wert, nur pos. gewichtet
- Jaccard-Maß, pos. und neg. gewichtet




Struktur/Inhalte der Ergebnistabelle (2)

- KOBV-Wert, nur pos. gewichtet
- Jaccard-Maß, pos. und neg. gewichtet
- Euklidischer Abstand, pos. und neg. gewichtet




Struktur/Inhalte der Ergebnistabelle (2)

- KOBV-Wert, nur pos. gewichtet
- Jaccard-Maß, pos. und neg. gewichtet
- Euklidischer Abstand, pos. und neg. gewichtet
- KOBV-Wert, pos. und neg. gewichtet




Was bleibt??

- jede Menge Ergebniszahlen, die „richtig“ interpretiert werden müssen




Was bleibt??

- jede Menge Ergebniszahlen, die „richtig“ interpretiert werden müssen
- empirische Überprüfung der Ergebnisse (Stichproben)



Was bleibt??

- jede Menge Ergebniszahlen, die „richtig“ interpretiert werden müssen
- empirische Überprüfung der Ergebnisse (Stichproben)
- Justierung der Schwellenwerte beim Jaccard-Maß (0.7 – 0.8)



Was bleibt??

- jede Menge Ergebniszahlen, die „richtig“ interpretiert werden müssen
- empirische Überprüfung der Ergebnisse (Stichproben)
- Justierung der Schwellenwerte beim Jaccard-Maß (0.7 – 0.8)
- Vorteil dieses Ansatzes: Ergebnisse können einander direkt gegenübergestellt werden



Vielen Dank für die
Aufmerksamkeit

