

Diplomarbeit

Intrinsische Plagiaterkennung am Beispiel einer Artikelsammlung

Marion Kulig

Weimar, 16. August 2006

Gliederung

1. Motivation
2. Algorithmen zu Erkennung von Plagiatvergehen
3. Methoden zur Quantifizierung von Stil
4. Ein Korpus zur Evaluierung von Plagiaterkennungsalgorithmen
5. Evaluierung
6. Ausblick und Zusammenfassung

Motivation

Plagiat = Diebstahl fremden geistigen Eigentums



[Quelle: Plagiat Design]



[Quelle: Plagiat Technik]



[Quelle: Plagiat Literatur]

[Quelle: Plagiat Kunst]

Motivation

Plagiat = Diebstahl fremden geistigen Eigentums

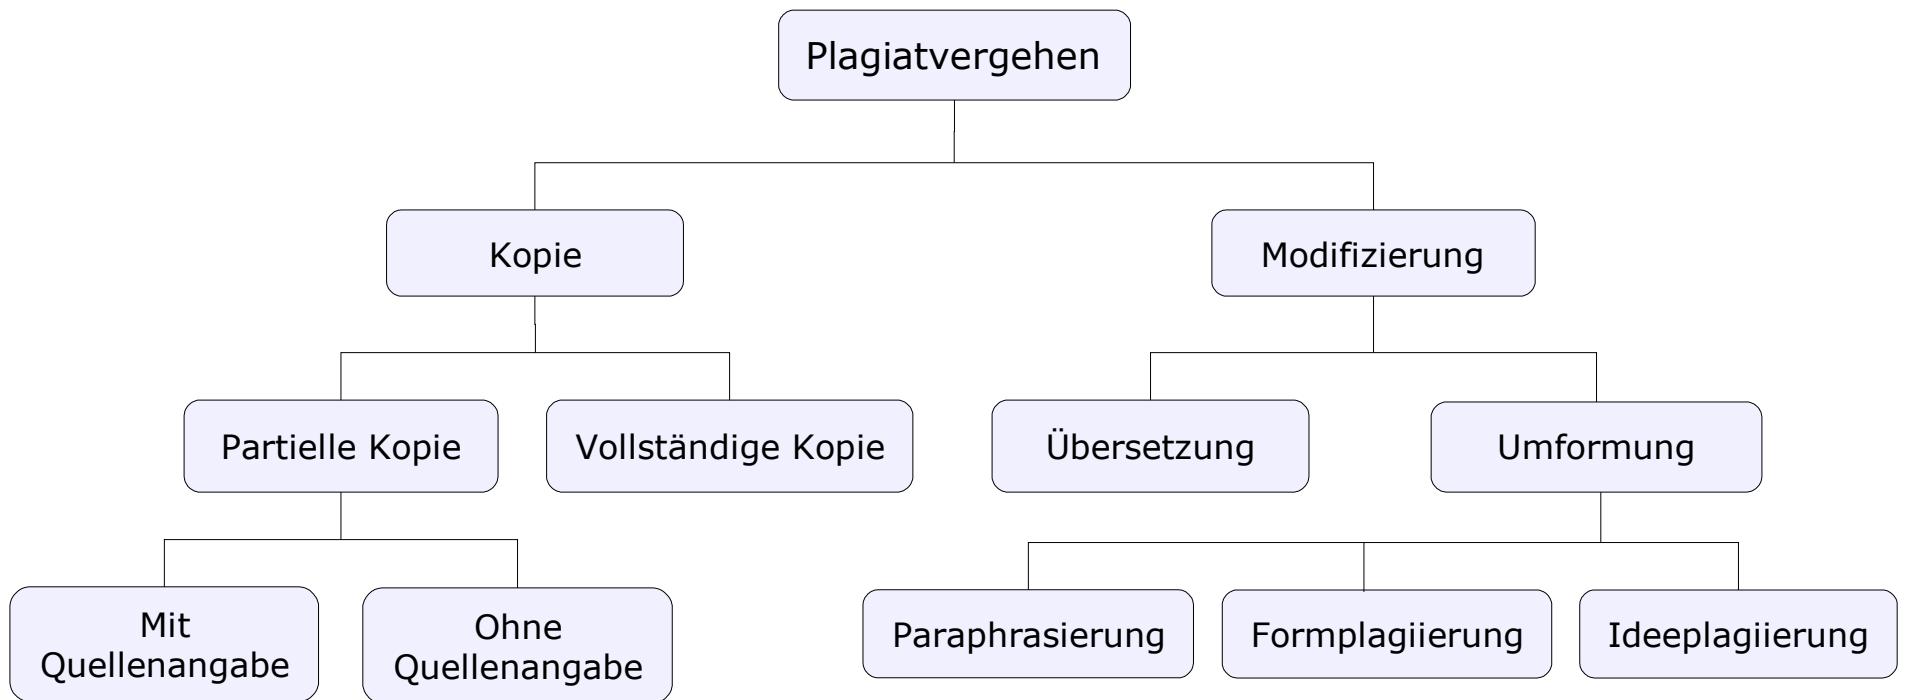


hausaufgaben-heute.com

► Biologie	► Informatik
► Chemie	► Kunst
► Deutsch	► Mathematik
► Englisch	► Physik
► Erdkunde	► Religion
► Französisch	► Sport
► Geschichte	► weitere Fächer

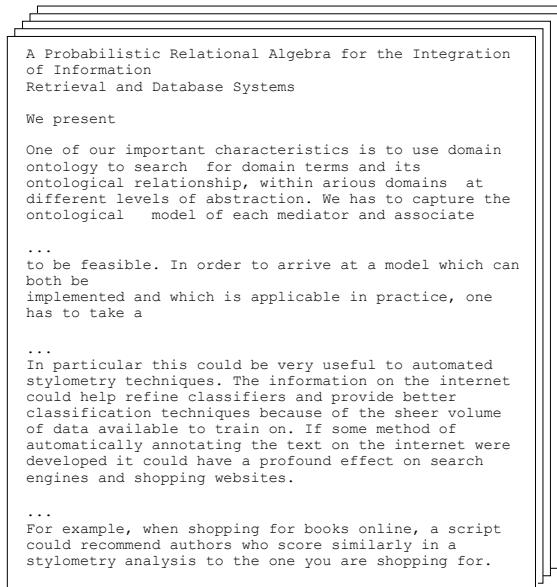
1 ANMELDEN
2 3000 HAUSAUFGABEN DOWNLOADEN

Taxonomie der Plagiate



Plagiatvergehen und deren Nachweis

Aufgabe: Finden von plagierten Abschnitten
(n Korpusdokumente, c Abschnitte pro Dok.)



A Probabilistic Relational Algebra for the Integration of Information Retrieval and Database Systems

We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

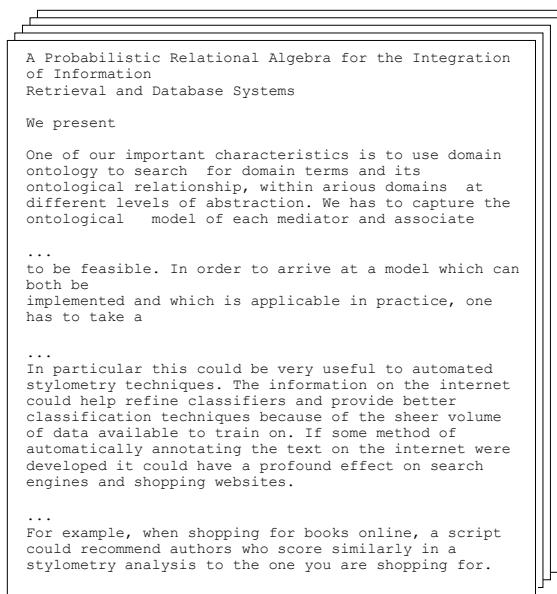
...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.

Korpus

Plagiatvergehen und deren Nachweis



A Probabilistic Relational Algebra for the Integration of Information Retrieval and Database Systems

We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

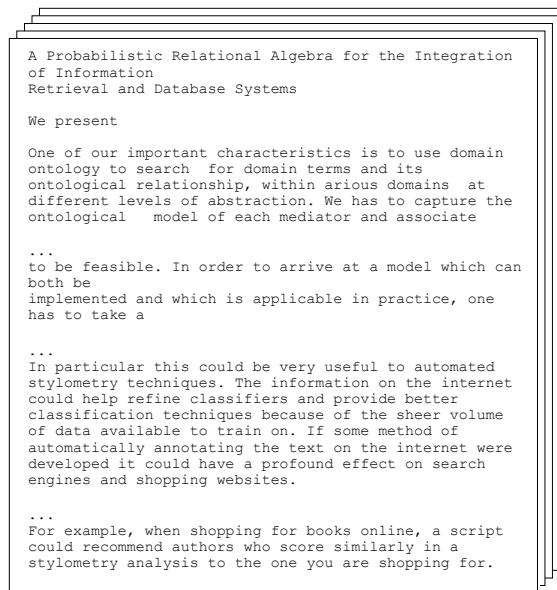
...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.

Korpus

Aufgabe: Finden von plagierten Abschnitten
(n Korpusdokumente, c Abschnitte pro Dok.)

- Paarweiser Abschnittsvergleich $O(n \cdot c^2)$

Plagiatvergehen und deren Nachweis

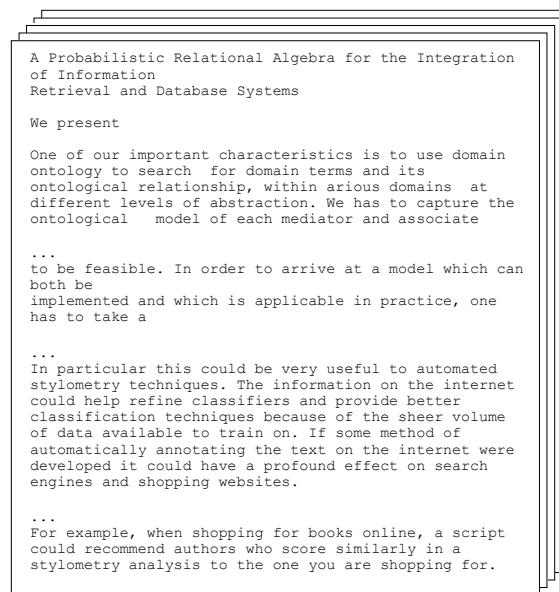


Aufgabe: Finden von plagierten Abschnitten
(n Korpusdokumente, c Abschnitte pro Dok.)

- Paarweiser Abschnittsvergleich $O(n \cdot c^2)$
- Hashing $O(n \cdot c)$

Korpus

Plagiatvergehen und deren Nachweis

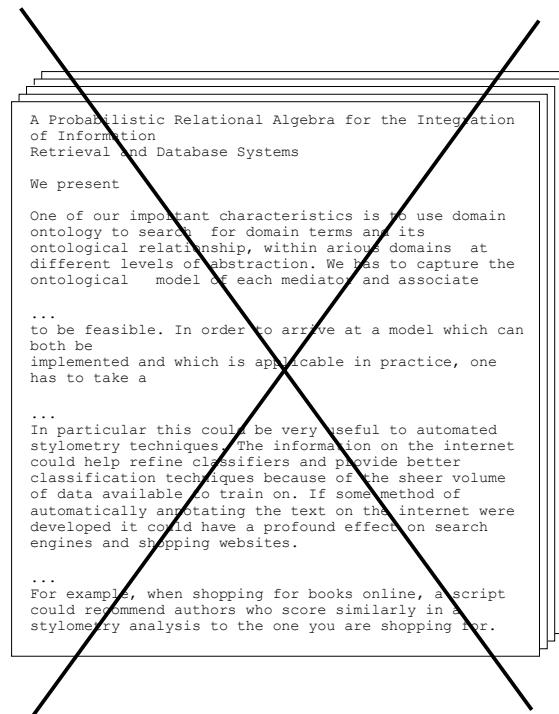


Korpus

Aufgabe: Finden von plagierten Abschnitten
(n Korpusdokumente, c Abschnitte pro Dok.)

- Paarweiser Abschnittsvergleich $O(n \cdot c^2)$
- Hashing $O(n \cdot c)$
- Fuzzy-Fingerprinting $O(n \cdot c)$

Plagiatvergehen und deren Nachweis



Korpus

?

Aufgabe: Finden von plagierten Abschnitten
(n Korpusdokumente, c Abschnitte pro Dok.)

- Paarweiser Abschnittsvergleich $O(n \cdot c^2)$
- Hashing $O(n \cdot c)$
- Fuzzy-Fingerprinting $O(n \cdot c)$

Stilanalyse

A Probabilistic Relational Algebra for the Integration
of Information
Retrieval and Database Systems

We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.

Stilanalyse

A Probabilistic Relational Algebra for the Integration
of Information
Retrieval and Database Systems

We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

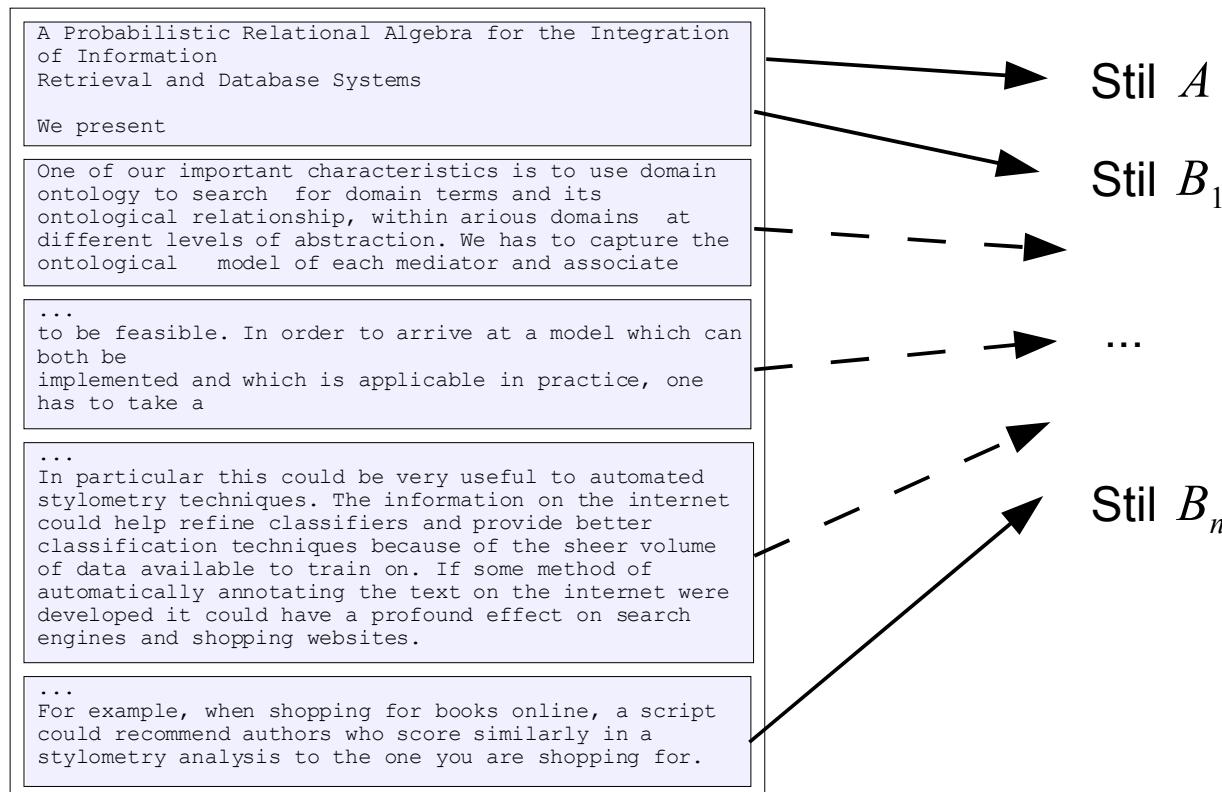
...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.

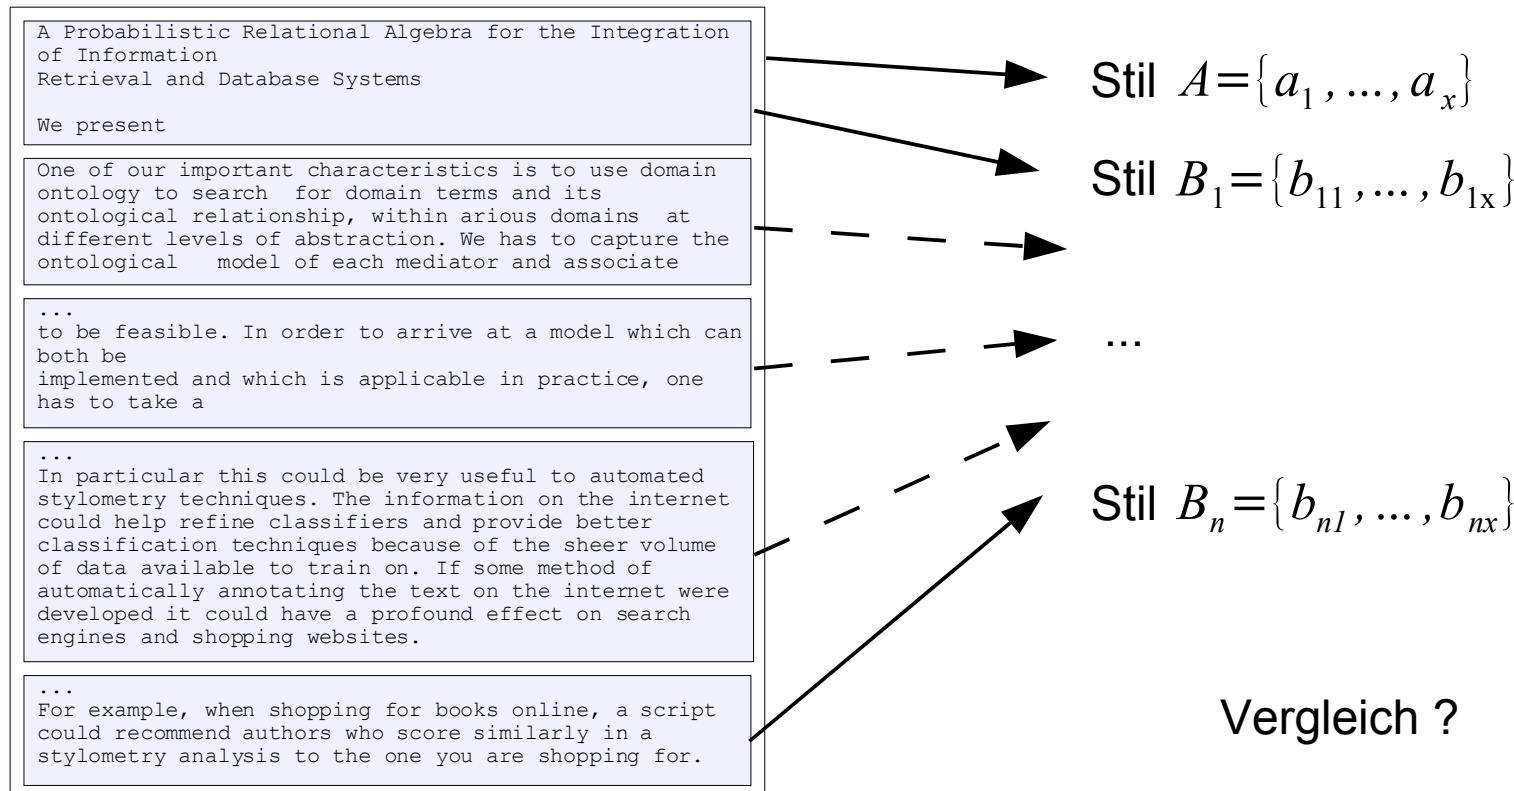


Stil A

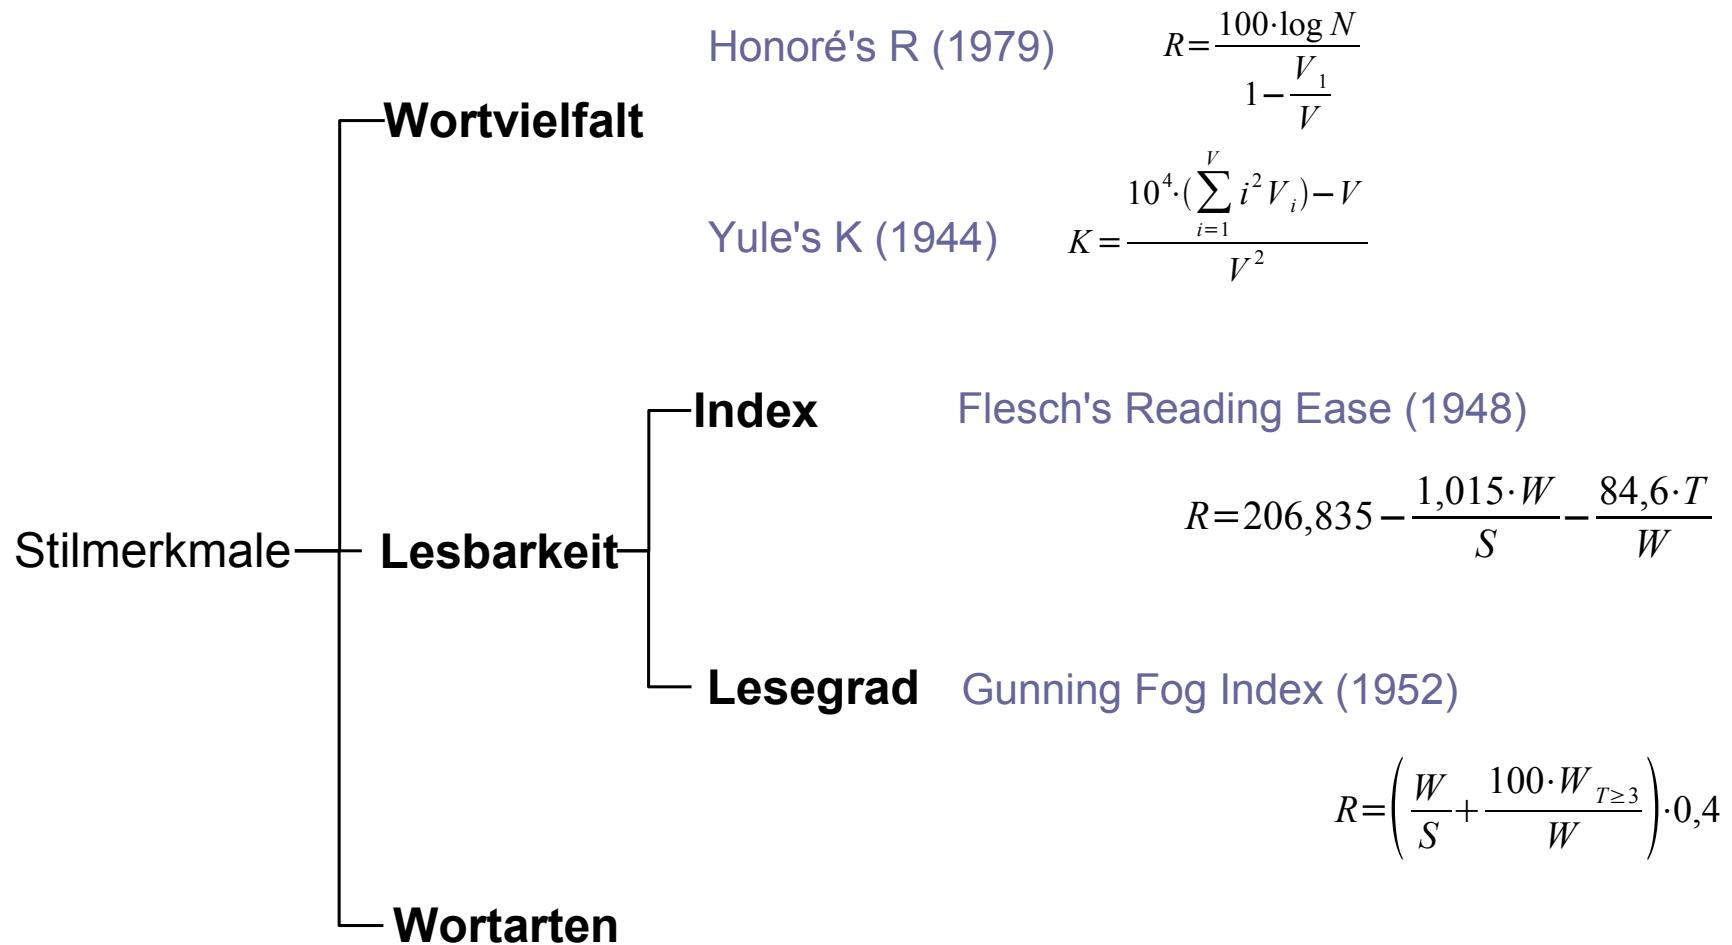
Stilanalyse



Stilanalyse



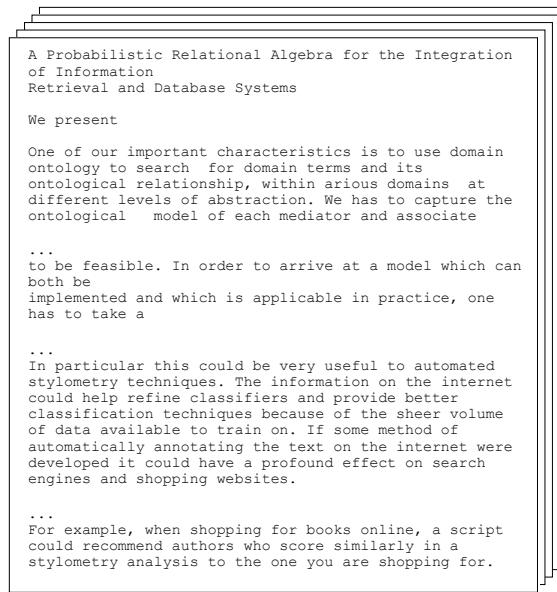
Methoden zur Quantifizierung von Stil



Übersicht Stilmerkmale

Maß	Stilmerkmal
einfache Stilmerkmale	\varnothing Satzlänge \varnothing Stoppwortanteil \varnothing Silbenanzahl pro Wort
Lesbarkeit	Flesch-Reading-Ease-Index FREI Flesch-Kincaid-Grade-Level FKGL Gunning-Fog-Index GFI Dale-Chall-Index DCI
Wortvielfalt	Honoré's R Yule's K Kullback-Leibler-Divergenz KLD Average-Word-Frequency-Class AWFC

Average-Word-Frequency-Class



Korpus

Average-Word-Frequency-Class

A Probabilistic Relational Algebra for the Integration of Information Retrieval and Database Systems

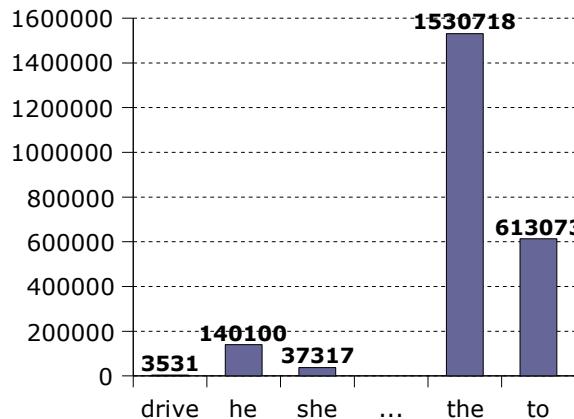
We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.



Korpus

Worthäufigkeiten jedes Wortes

Average-Word-Frequency-Class

A Probabilistic Relational Algebra for the Integration of Information Retrieval and Database Systems

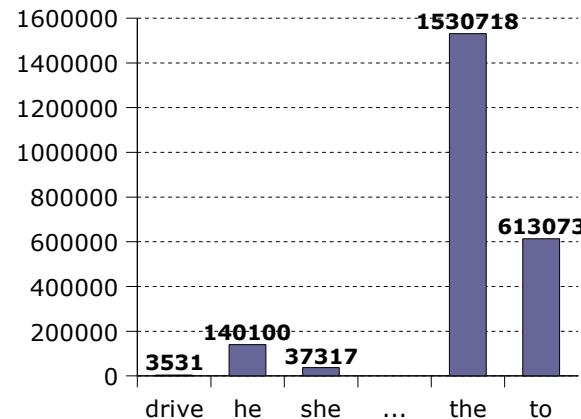
We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.



the	0
to	1
he	3
she	5
drive	8
...	...
polyethnicity	18
...	...
	19

Korpus

Worthäufigkeiten jedes Wortes

Häufigkeitsklasse

Average-Word-Frequency-Class

Maß für die durchschnittliche Worthäufigkeitsklasse eines Dokuments

C ... Textkorpus

$f(w)$... Worthäufigkeit eines Wortes $w \in C$

$c(w)$... Häufigkeitsklasse eines Wortes

$$c(w) = \left\lfloor \log_2(f(w^*)/f(w)) \right\rfloor$$

w^* ... häufigstes Wort in C , hier das Wort „the“ mit entsprechender Häufigkeitsklasse 0. Das seltenste hat die 18.

Ein Korpus zur Erkennung von Plagiaterkennungsalgorithmen

- 100 Dokumente aus ACM-Bibliothek im PDF-Format
- Aus 3 Themengebieten (Information Retrieval, CSCW, und Plagiarism)
- Übertragung ins XML-Format
- Einfügen von plagiierten Abschnitten (copied / modified)
- Kennzeichnung des Ursprungs

```
<?xml version="1.0" encoding="UTF-8"?>
<document xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:noNamespaceSchemaLocation="collection_schema.xsd"
documentSource="http://portal.acm.org/citation.cfm?doid=239041.239045">
  A Probabilistic Relational Algebra for the Integration of
  Information Retrieval and Database Systems NORBERT FUHR and
  THOMAS RO" LLEKE University of Dortmund
  We present
  ...
<inserted
  source="http://portal.acm.org/citation.cfm?doid=375212.375229"
  type="modified">
  One of our important characteristics is to use domain ontology to
  search for domain terms and its ontological relationship, within
  various domains at different levels of abstraction. We has to
  capture the ontological model of each mediator and associate
  ...
</inserted>
  ...
  to be feasible. In order to arrive at a model which can both be
  implemented and which is applicable in practice, one has to take a
  ...
<inserted source="..." type="..."
  ...
</inserted>
  ...
  ...
  ...
</document>
```

Fragestellungen

1. Können plagierte Abschnitte intrinsisch durch den Einsatz von Stilmerkmalen erkannt werden?

Fragestellungen

1. Können plagierte Abschnitte intrinsisch durch den Einsatz von Stilmerkmalen erkannt werden?
2. Wie gut können plagierte Abschnitte erkannt werden?

Fragestellungen

1. Können plagierte Abschnitte intrinsisch durch den Einsatz von Stilmerkmalen erkannt werden?
2. Wie gut können plagierte Abschnitte erkannt werden?
3. Gibt es signifikante Unterschiede zwischen verschiedenen Themengebieten? Ist eine Themenabhängigkeit vorhanden?

Fragestellungen

1. Können plagierte Abschnitte intrinsisch durch den Einsatz von Stilmerkmalen erkannt werden?
2. Wie gut können plagierte Abschnitte erkannt werden?
3. Gibt es signifikante Unterschiede zwischen verschiedenen Themengebieten? Ist eine Themenabhängigkeit vorhanden?
4. Ab welchem plagierten Anteil können plagierte Abschnitte zuverlässig bestimmt werden?

Fragestellungen

1. Können plagierte Abschnitte intrinsisch durch den Einsatz von Stilmerkmalen erkannt werden?
2. Wie gut können plagierte Abschnitte erkannt werden?
3. Gibt es signifikante Unterschiede zwischen verschiedenen Themengebieten? Ist eine Themenabhängigkeit vorhanden?
4. Ab welchem plagierten Anteil können plagierte Abschnitte zuverlässig bestimmt werden?
5. Gibt es Stilmerkmale, die besonders gut und besonders schlecht funktionieren?

Fragestellungen

1. Können plagierte Abschnitte intrinsisch durch den Einsatz von Stilmerkmalen erkannt werden?
2. Wie gut können plagierte Abschnitte erkannt werden?
3. Gibt es signifikante Unterschiede zwischen verschiedenen Themengebieten? Ist eine Themenabhängigkeit vorhanden?
4. Ab welchem plagierten Anteil können plagierte Abschnitte zuverlässig bestimmt werden?
5. Gibt es Stilmerkmale, die besonders gut und besonders schlecht funktionieren?
6. Wie stabil funktionieren die Stilmerkmale in Abhängigkeit der Textlänge?

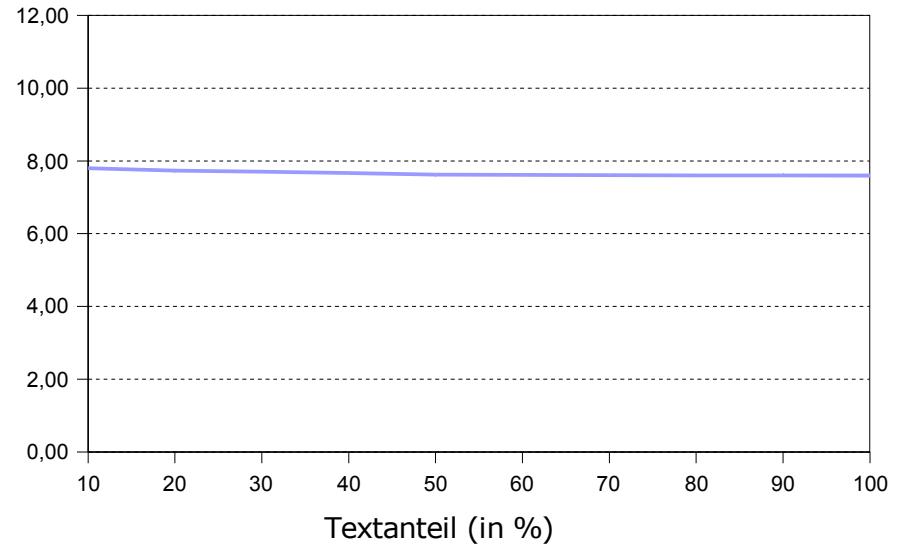
Stabilität der Stilmerkmale

Stilmerkmale müssen auf Textabschnittsebene zuverlässig funktionieren.

Bedingungen:

1. Die Merkmale sollten unabhängig vom verwendeten Textumfang möglichst konstante Werte liefern.

Idealisierte Darstellung



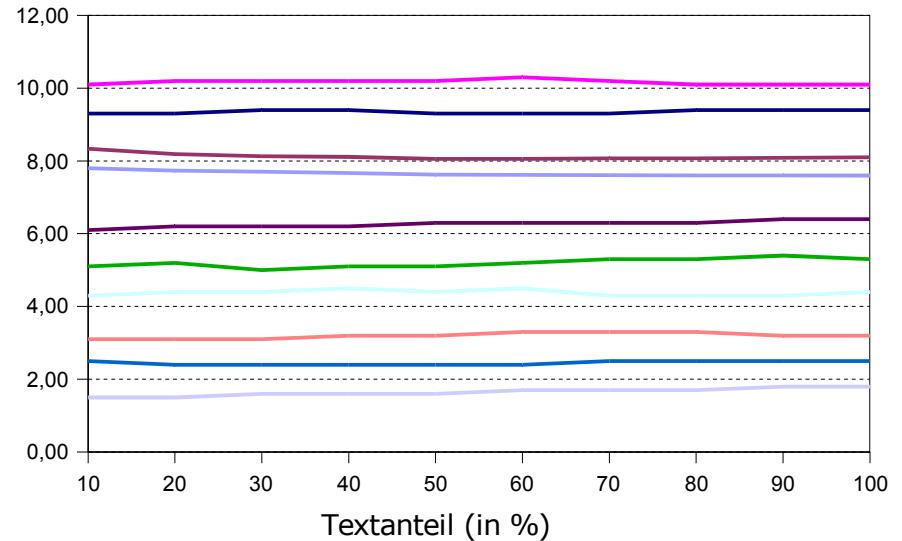
Stabilität der Stilmerkmale

Stilmerkmale müssen auf Textabschnittsebene zuverlässig funktionieren.

Bedingungen:

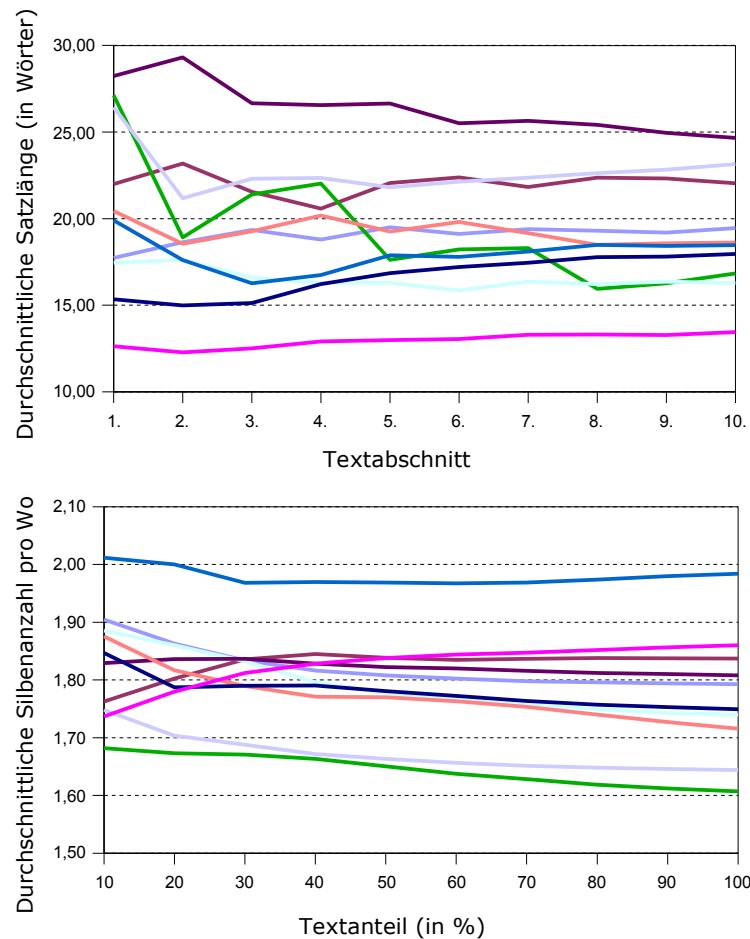
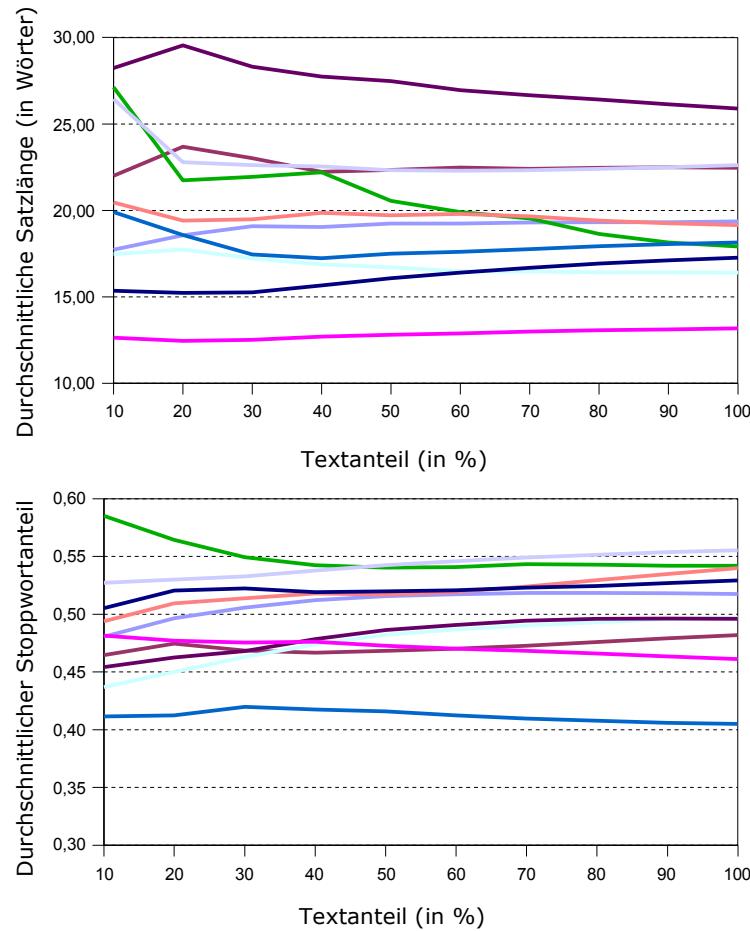
1. Die Merkmale sollten unabhängig vom verwendeten Textumfang möglichst konstante Werte liefern.
2. Die Unterschiede von Werten verschiedener Texte sollten möglichst groß sein.

Idealisierte Darstellung



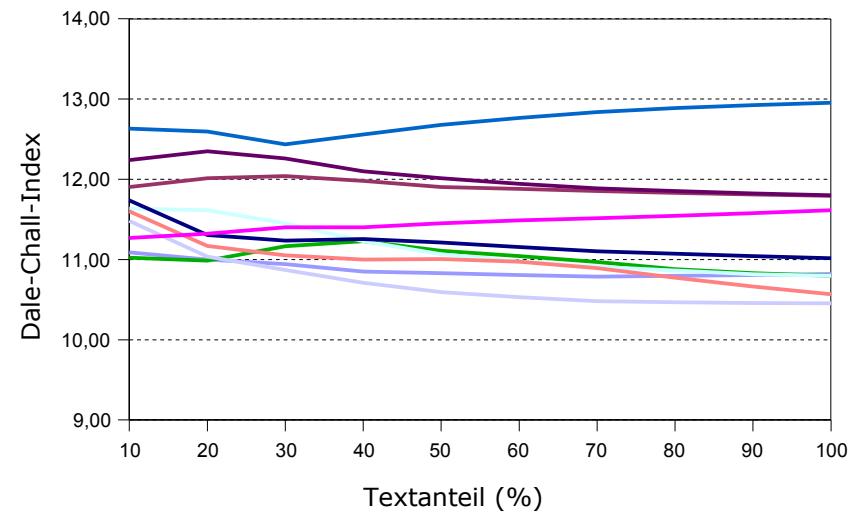
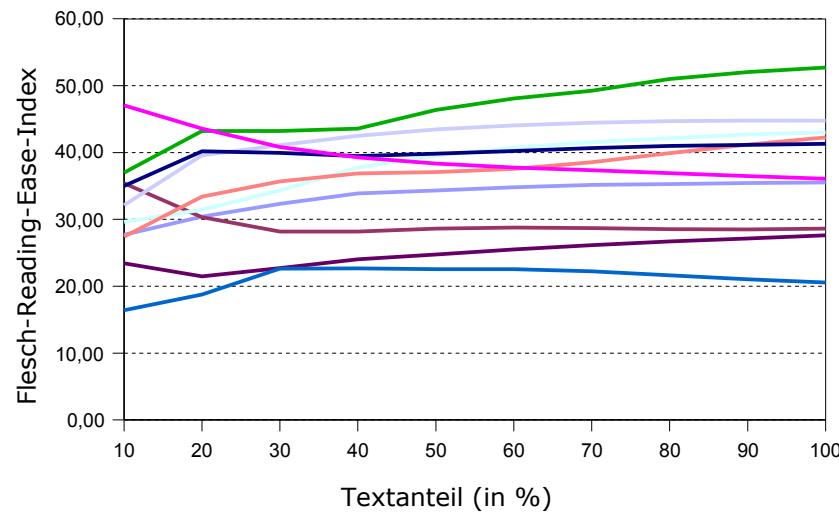
Stabilität der Stilmerkmale

1. Ergebnisse: einfache Stilmerkmale



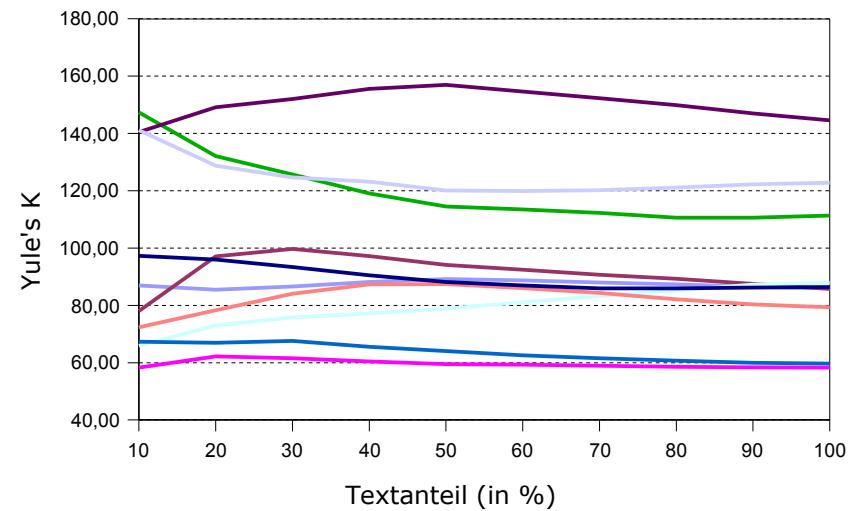
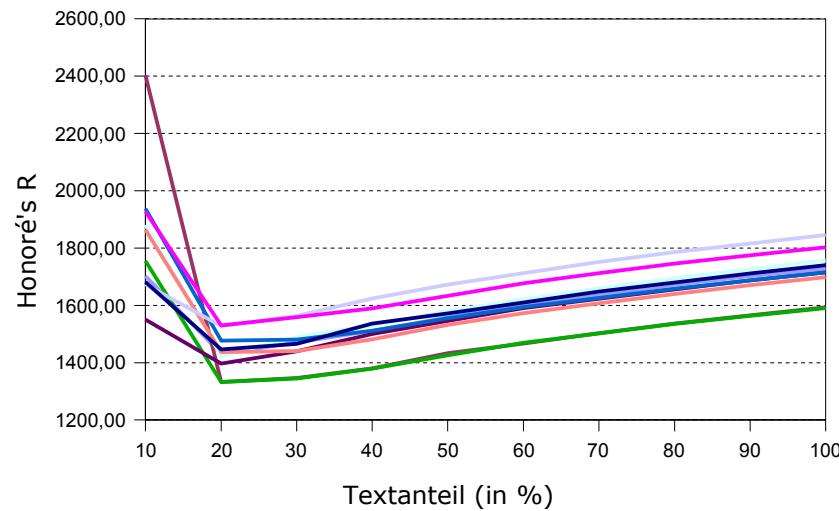
Stabilität der Stilmerkmale

2. Ergebnisse: Lesbarkeitsformeln



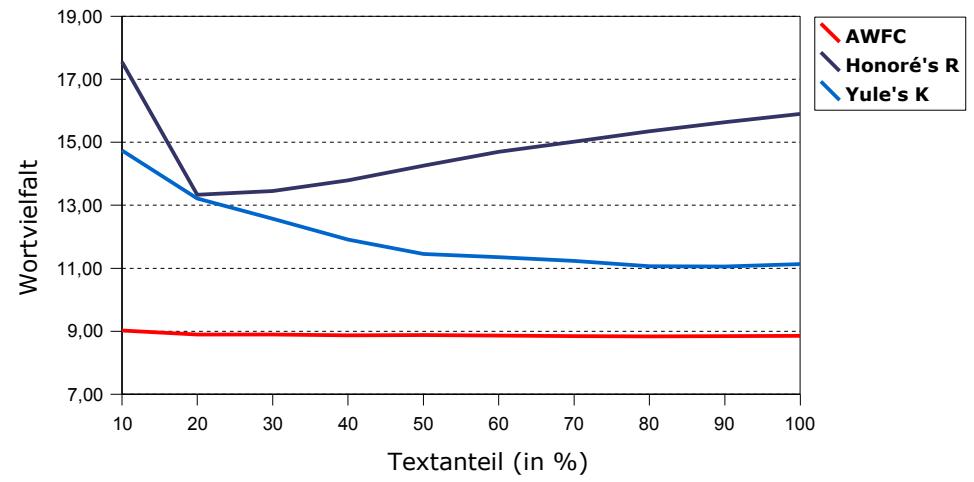
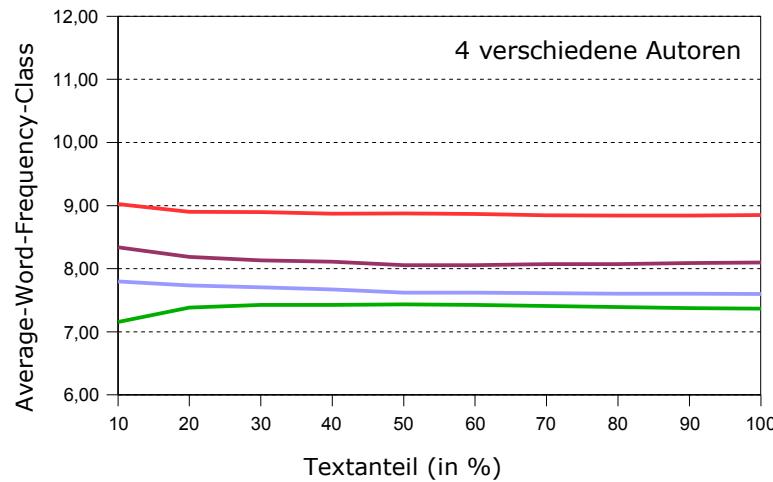
Stabilität der Stilmerkmale

3. Ergebnisse: Maße zur Berechnung der Wortvielfalt



Stabilität der Stilmerkmale

4. Ergebnisse: Average-Word-Frequency-Class



Experiment – Plagiaterkennung

Generierung von Features:

a ... Stilmerkmalswert eines
Dokuments

b ... Stilmerkmalswert eines
Abschnitts des selben
Dokuments

Feature F :

$$f(a, b) = 2 \cdot \left(\frac{a}{a+b} \right) - 1$$

[-1, +1]

Experiment – Plagiaterkennung

Generierung von Features:

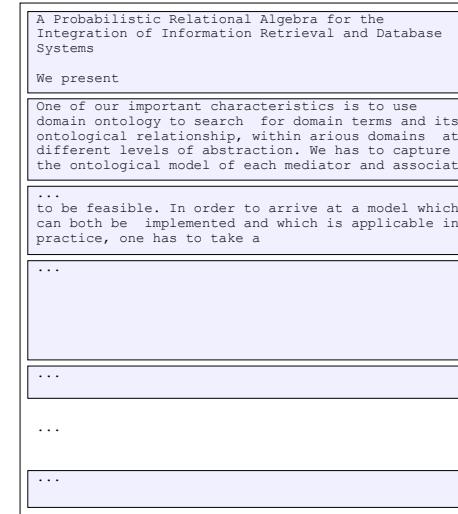
a ... Stilmerkmalswert eines Dokuments

b ... Stilmerkmalswert eines Abschnitts des selben Dokuments

Feature F :

$$f(a, b) = 2 \cdot \left(\frac{a}{a+b} \right) - 1$$

$[-1, +1]$



Dokument

Experiment – Plagiaterkennung

Generierung von Features:

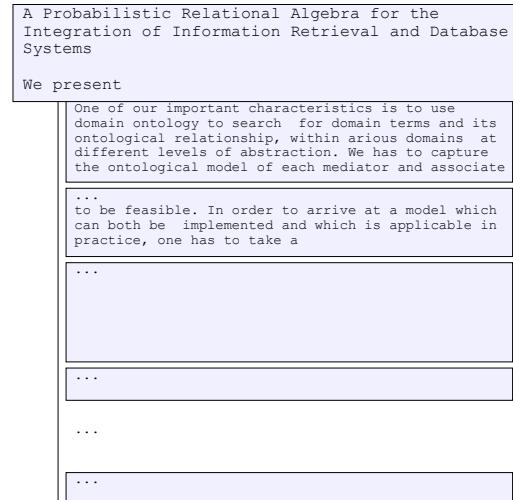
a ... Stilmerkmalswert eines Dokuments

b ... Stilmerkmalswert eines Abschnitts des selben Dokuments

Feature F :

$$f(a, b) = 2 \cdot \left(\frac{a}{a+b} \right) - 1$$

$[-1, +1]$



Dokument

Experiment – Plagiaterkennung

Generierung von Features:

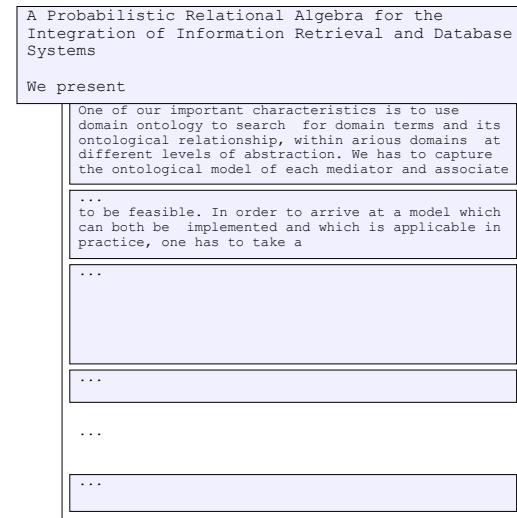
a ... Stilmerkmalswert eines Dokuments

b ... Stilmerkmalswert eines Abschnitts des selben Dokuments

Feature F :

$$f(a, b) = 2 \cdot \left(\frac{a}{a+b} \right) - 1$$

$[-1, +1]$



Dokument

0
0.06726565458363455
0.07382682112703698
0.028303395341399806
0.3868205645891639
-0.04233882159629632
0.17648668601777584
-0.03759439698950884
-0.009972288405130092
-0.02760080047851632
-0.11936032408952169
-0.025668683521426705
0.03675341943041821
0.24849370093116674
-0.4603512506652475
1.0
0.029065359146742242
0.35752751112151726
-0.2251367340104924
-0.9009352268791133
0.0
1.0
0.0
1.0
-0.01406368694438176
0.3246369677578145
1.0
1.0
-0.9269662921348315
1.0
-0.19855235242730562

Feature-Datei

Experiment – Plagiaterkennung

- 3200 Korpus-Dokumente
- ca. 70 Textabschnitte pro Dokument
- => 224.000 Feature-Datensätze

Experiment – Plagiaterkennung

- 3200 Korpus-Dokumente
- ca. 70 Textabschnitte pro Dokument
- => 224.000 Feature-Datensätze
- ca. 600 verschiedene plagierte Abschnitte

Thema	Anzahl Abschnitte	davon plagiert
CSCW	68704	4704
Information Retrieval	99552	4449
Plagiarism	54640	3760
Gesamt	222896	12913

Precision und Recall

		Tatsächliche Gruppenzugehörigkeit	
		Plagiat	kein Plagiat
Vorhergesagte Gruppenzugehörigkeit	Plagiat	a) Richtig Positiv	b) Falsch Positiv
	kein Plagiat	c) Falsch Negativ	d) Richtig Negativ

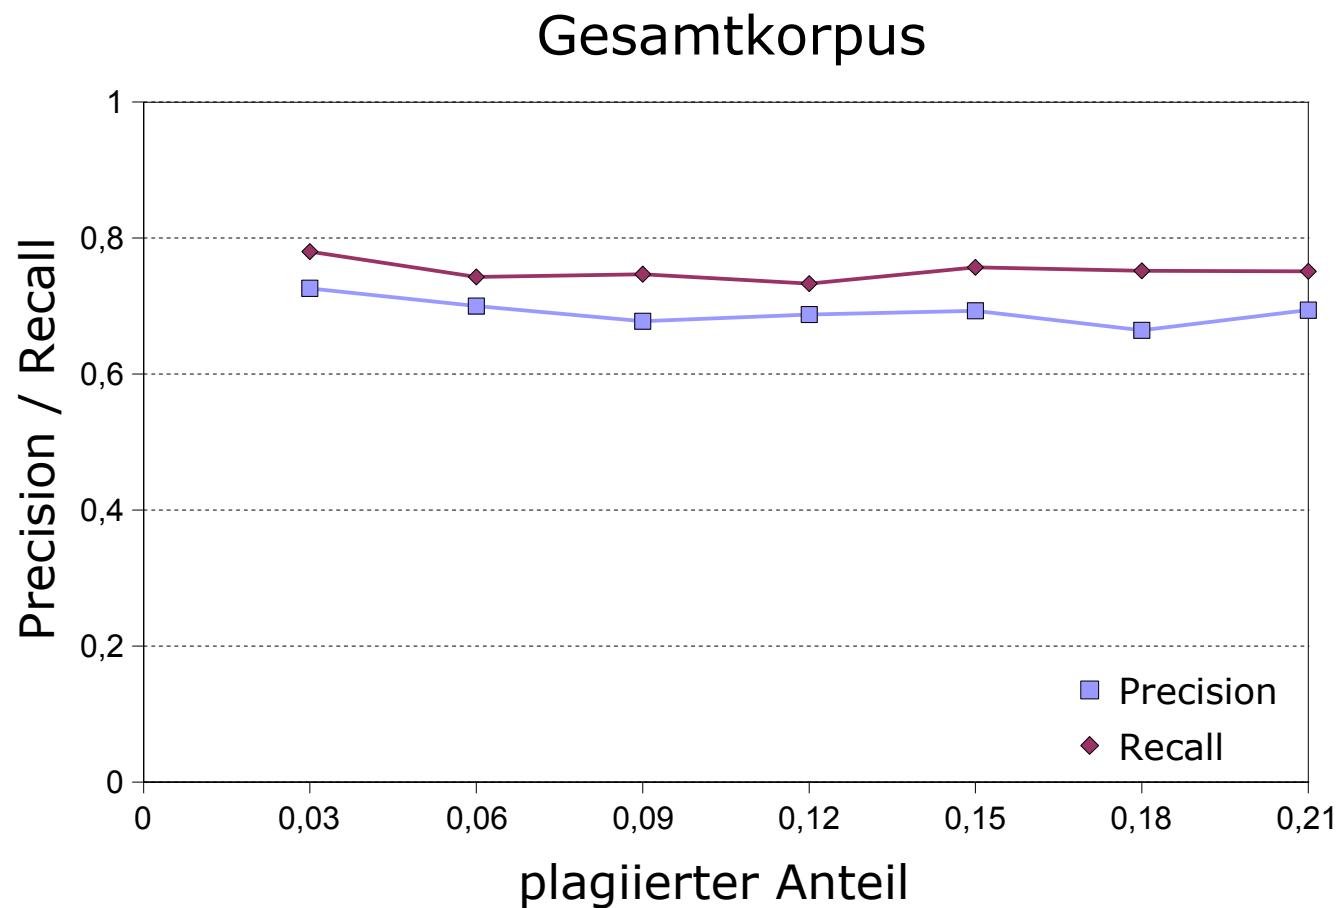
Precision:

$$P = \frac{a}{(a+b)}$$

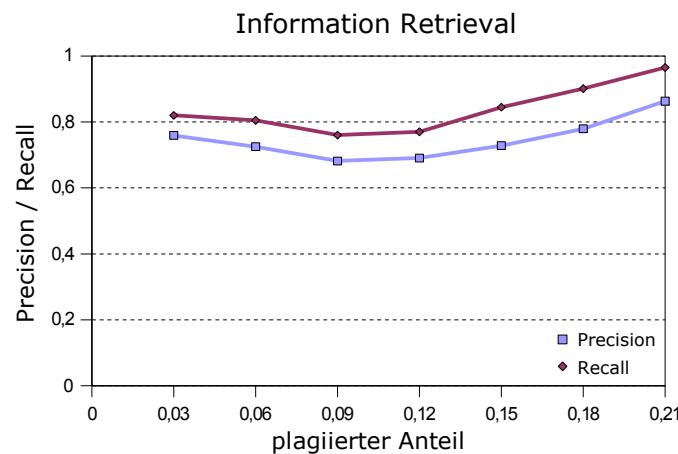
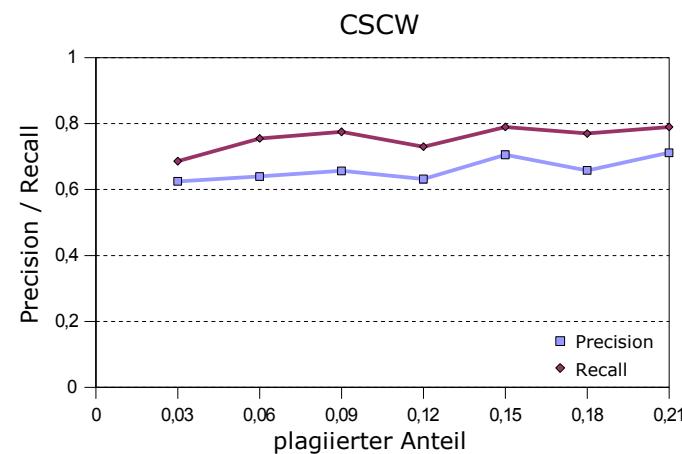
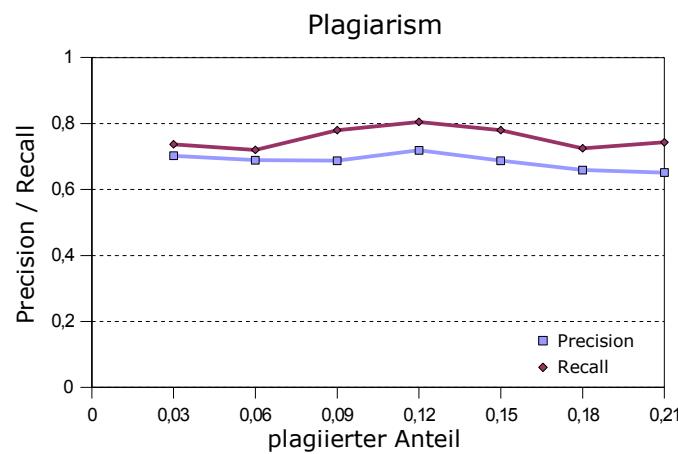
Recall:

$$R = \frac{a}{(a+c)}$$

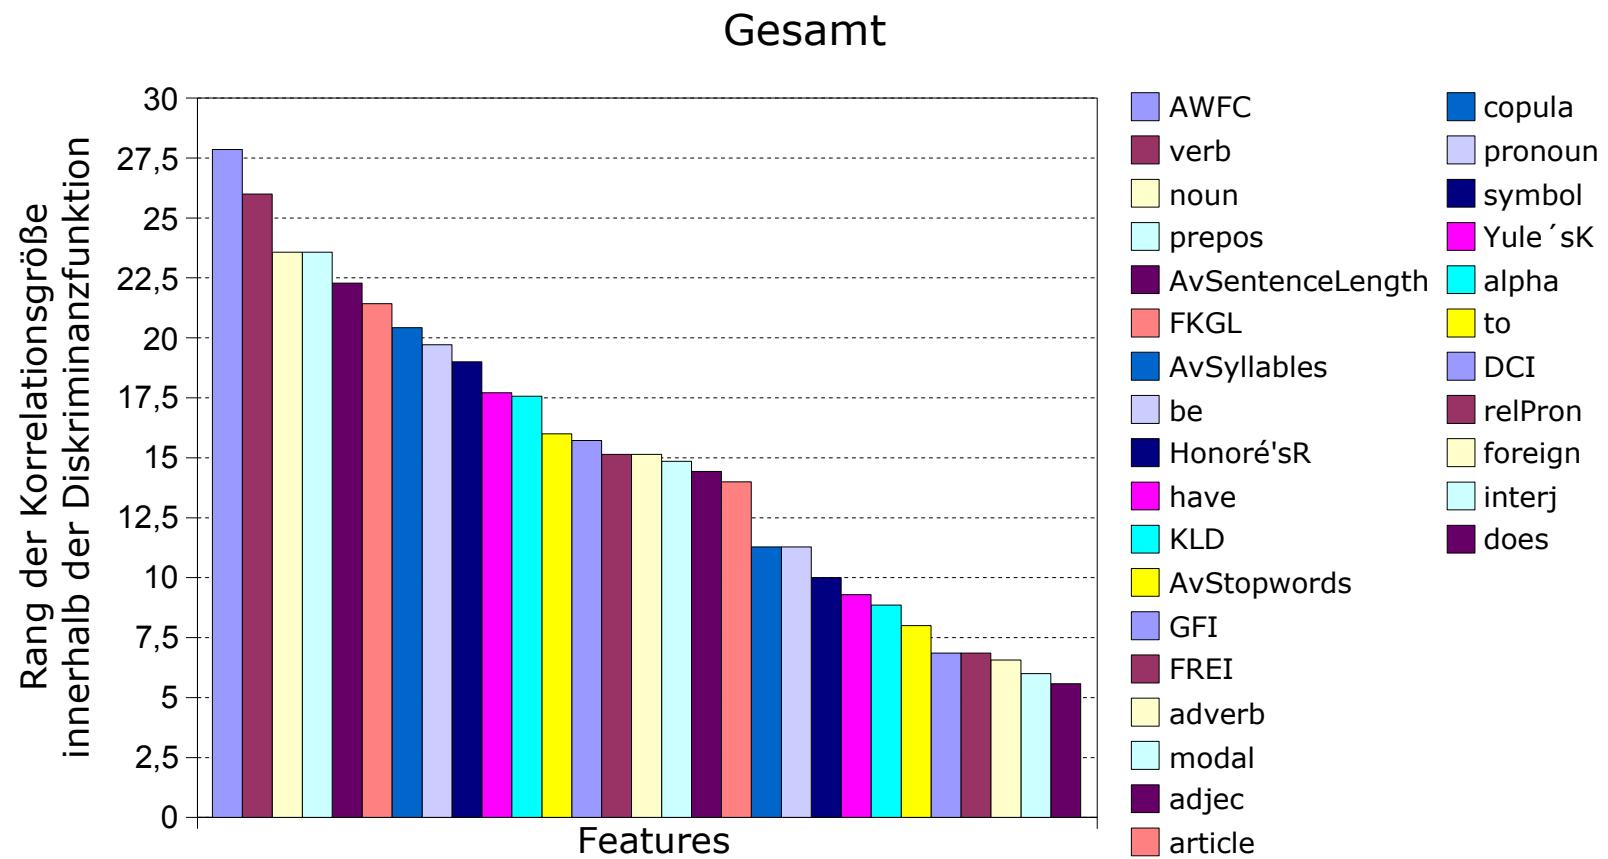
Ergebnisse



Ergebnisse



Ergebnisse



Zusammenfassung und Ausblick

- Experimente zur intrinsischen Plagiaterkennung unter Verwendung von Stilmerkmalen lieferten vielversprechende Ergebnisse.
- Precision 70 %, Recall 75%
- Anwendungsmöglichkeit liegt in der Vorauswahl verdächtiger Abschnitte, deren Ursprung dann gefunden werden muss.

Vielen Dank für Ihre Aufmerksamkeit

Literaturverzeichnis

Plagiat Technik: http://www.plagiarius.com/img/2006_09_s.jpg

Plagiat Design: http://www.plagiarius.com/img/2006_03_s.jpg

Plagiat Kunst: <http://www.hinternet.de/musik/interview/images/plagiari.jpg>

Plagiat Literatur: <http://www.forumakad.pl/archiwum/99/4/images/image004.jpg>

Meyer zu Eißen, B. Stein: *Intrinsic Plagiarism Detection*. Proceedings of the European Conference on Information Retrieval (ECIR-06), 2006

Precision und Recall

Beispiel: Precision = 80 %,

Recall = 20%

A Probabilistic Relational Algebra for the Integration of Information Retrieval and Database Systems

We present

One of our important characteristics is to use domain ontology to search for domain terms and its ontological relationship, within various domains at different levels of abstraction. We have to capture the ontological model of each mediator and associate

...
to be feasible. In order to arrive at a model which can both be implemented and which is applicable in practice, one has to take a

...
In particular this could be very useful to automated stylometry techniques. The information on the internet could help refine classifiers and provide better classification techniques because of the sheer volume of data available to train on. If some method of automatically annotating the text on the internet were developed it could have a profound effect on search engines and shopping websites.

...
For example, when shopping for books online, a script could recommend authors who score similarly in a stylometry analysis to the one you are shopping for.



Plagiatanalyse:

10 des Plagiats verdächtige Abschnitte gefunden

Precision: 8 von diesen 10 sind plagiert. 2 sind nicht plagiert.

Recall: Die 8 gefundenen entsprechen 20 % aller im Text plagierten Abschnitte (insgesamt 40).