

Plagiate, und wie (gut) man sie erkennen kann

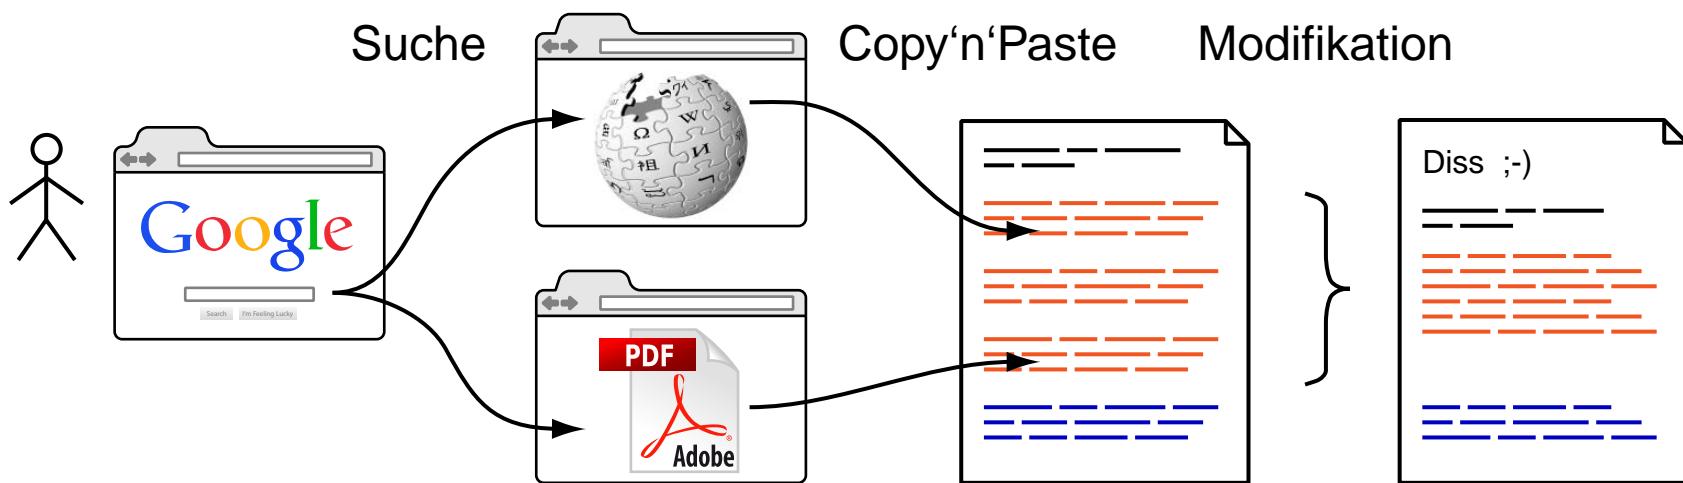
Technologien zur Wiederverwendung von Texten aus dem Web

Martin Potthast

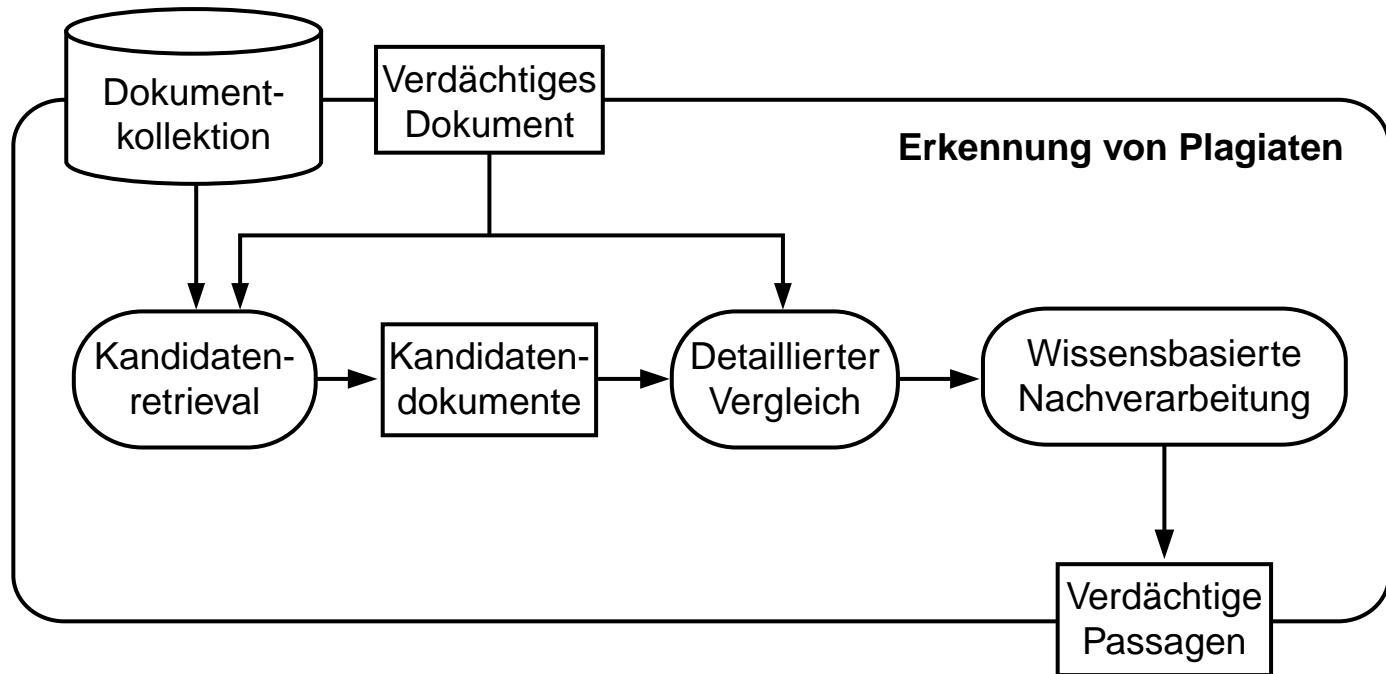
Bauhaus-Universität Weimar

www.webis.de

Wie Menschen plagiiieren

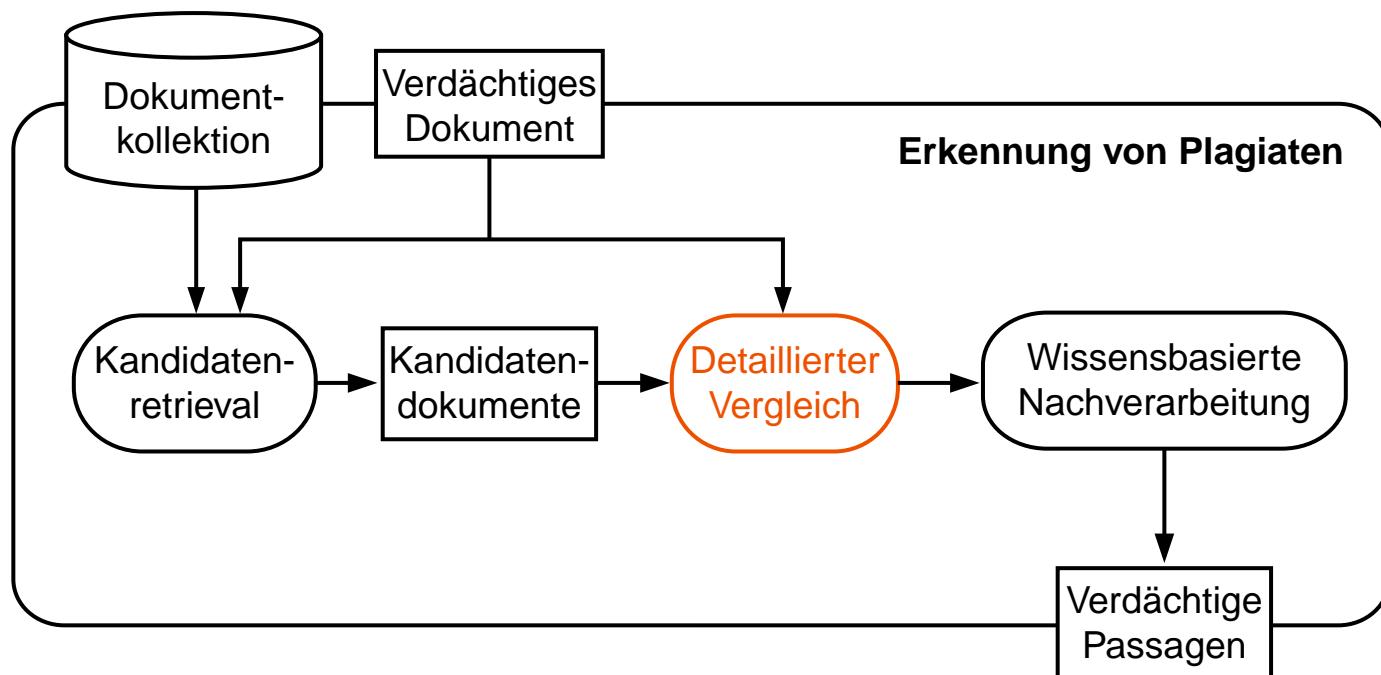


Wie Maschinen Plagiate erkennen



Wie Maschinen Plagiate erkennen

- Wie können sprachübergreifende Plagiate erkannt werden?
- Wie verlässlich sind Algorithmen zur Plagiatserkennung?



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chattrapur, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to Maida Vale, London, where Alan Turing was born on 23 June 1912. He had an elder brother, John. His father's civil service commission was still active, and during Turing's childhood years his parents travelled between Hastings, England and India, leaving their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius he was to later prominently display.



Alan Mathison Turing was born on 23 June 1912. His father was Julius Mathison Turing, member of the civil service in India, and his mother Ethel Sara Turing, the daughter of Edward Waller Stoney. Alan's childhood was spent with his elder brother John, living with a retired Army couple near Hastings, England. His parents returned to India until the end of his father's civil service commission, and visited when they could. Signs of Turing's genius showed early in his life. It is reported that he taught himself reading in less than three weeks.



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chattrapur, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to Maida Vale, London, where Alan Turing was born on 23 June 1912. He had an elder brother, John. His father's civil service commission was still active, and during Turing's childhood years his parents travelled between Hastings, England and India, leaving their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius he was to later prominently display.



Alan Mathison Turing was born on 23 June 1912. His father was Julius Mathison Turing, member of the civil service in India, and his mother Ethel Sara Turing, the daughter of Edward Waller Stoney. Alan's childhood was spent with his elder brother John, living with a retired Army couple near Hastings, England. His parents returned to India until the end of his father's civil service commission, and visited when they could. Signs of Turing's genius showed early in his life. It is reported that he taught himself reading in less than three weeks.



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chattrapur, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan turing travel teach army alan active

4
1
0
:
1
3
1

turing travel teach army alan active

4
1
0
:
1
3
1

4
1
0
:
1
3
1



Alan Mathison Turing was born on 23 June 1912. His father was Julius Mathison Turing, member of the civil service in India, and his mother Ethel Sara Turing, the daughter of Edward Waller Stoney. Alan's childhood was spent with his elder brother John, living with a retired Army couple near Hastings, England. His parents returned to India until the end of his father's civil service commission, and visited when they could. Signs of Turing's genius showed early in his life. It is reported that he taught himself reading in less than three weeks.

5
0
1
:
1
2
0



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chattrapur, Orissa, India. His father was a member of the Indian Civil Ser-

turing	4
travel	1
teach	0
:	:
army	1
alan	3
active	1

φ

- Euklidische Distanz
- Skalarprodukt
- Kosinusähnlichkeit

5
0
1
:
1
2
0

... early in life, Turing showed signs of the genius he was to later prominently display.



Alan Mathison Turing was born on 23 June 1912. His father was Julius Mathison Turing, member of the

... his the ... Stoney. ... with his ... with a ... Hastings, ... turned to ... father's ... and visi- ... s of ... early in his ... caught ...

... million reading in less than three weeks.



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chatrapur, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to Maida Vale, London, where Alan Turing was born on 23 June 1912. He had an elder brother, John. His father's civil service commission was still active, and during Turing's childhood years his parents travelled between Hastings, England and India, leaving their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius he was to later prominently display.



Turings Vater Julius Mathison Turing, ein britischer Staatsdiener in Chatrapur, Indien, und dessen Frau Ethel Sara wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrten sie nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Staatsdienst seines Vaters noch nicht beendet war, pendelte dieser während Turings Kindheit zwischen England und Indien. Seine Familie ließ er aus Furcht vor Gefahren in der britischen Kolonie bei Freunden in England zurück. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Turings.



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chatrapur, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to Maida Vale, London, where Alan Turing was born on 23 June 1912. He had an elder brother, John. His father's civil service commission was still active, and during Turing's childhood years his parents travelled between Hastings, England and India, leaving their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius he was to later prominently display.



Turing's Vater Julius Mathison Turing, ein britischer Staatsdiener in Chatrapur, Indien, und dessen Frau Ethel Sara wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrten sie nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Staatsdienst seines Vaters noch nicht beendet war, pendelte dieser während Turings Kindheit zwischen England und Indien. Seine Familie ließ er aus Furcht vor Gefahren in der britischen Kolonie bei Freunden in England zurück. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Turings.



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chatrapur, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan turing travel two britisch beendet alan

4
1
1
0
0
3



Turings Vater Julius Mathison Turing, ein britischer Staatsdiener in Chatrapur, Indien, und dessen Frau Ethel Sara wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrten sie nach London-Paddington zurück, wo Alan Turing am 20. Juni 1912 zur Welt kam. Da der Staatsdienst seines Vaters noch nicht beendet war, pendelte dieser während Turings Kindheit zwischen England und Indien. Seine Familie ließ er aus Furcht vor Gefahren in der britischen Kolonie bei Freunden in England zurück. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Turings.

5
0
0
2
1
1



Messung sprachübergreifender Textähnlichkeit

Alan Turing was conceived at Chatrapur, Orissa, India. His father was a member of the Indian Civil Ser-

turing	4
travel	1
two	1
:	:
britisch	0
beendet	0
alan	3

~~φ~~

ausgenommen
- Syntaxüberlappung
- Autom. Übersetzung

5
0
0
:
2
1
1

Early in life, Turing showed signs of the genius he was to later prominently display.



Turings Vater Julius Mathison Turing, ein britischer Staatsdiener in Chatrapur, Indien, und dessen

ass ihr
boren
nach
k, wo
912 zur
ienst
beendet
end
England
ließ er
n der
unden in
frühester
Kindheit zeigte sich die hohe Begabung und Intelligenz Turings.



Cross-language Explicit Semantic Analysis (CL-ESA)

Alan Turing was conceived at Charsworth Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to Ida Vale, London, where Alan was born on 23 June 1912. He had an elder brother, John. His father's civil service career was still active, and during Alan's childhood years his parents travelled between England and India, leaving their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius he was to later prominently display.

4
:
1

⊗
~~⊗~~

Turing's Father Julius Mathison Turing, ein britischer Statistiker in Charsworth, Indien, und dessen Frau Ethel wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrte er nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Vater erst seines Vaters reichte, wurde es beendet war, pendelte er zwischen Indien und England. Beide waren sie sehr eng mit den Eltern zusammen. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Tinterns.

5
:
0

Cross-language Explicit Semantic Analysis (CL-ESA)

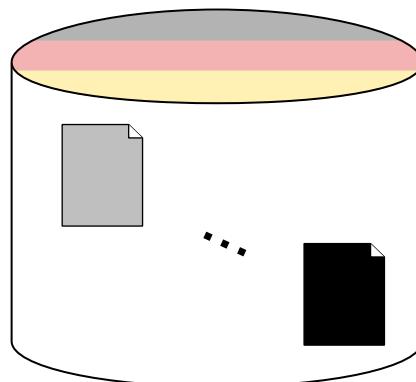
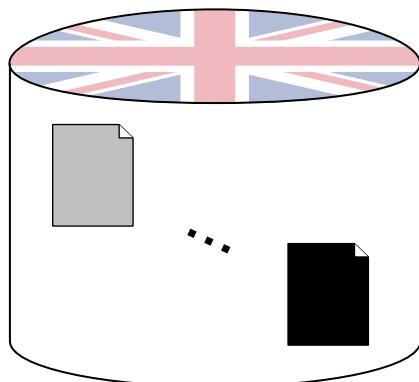
Alan Turing was conceived at Cheshire Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to India Vale, London, where Alan was born on 23 June 1912. He had an elder brother, John. His father's civil service career was still active, and during ~~and~~ ^{his} childhood years his parents travelled between England, England and India, taking their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius. He was to later prominently display.

4
1



Turing's Father Julius Mathison Turing, ein britischer Statistiker in Cheshire, Indien, und dessen Frau Ethel wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrte er nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Vater erst seines Vaters reichte, wurde sein Vater beendet war, pendelte er zwischen Indien und England. Seine Mutter ließ er aus Furcht vor dem Krieg in die Britische Armee bei Freunden in England zurück. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Tinterns.

5
4
3
2
1
0



Cross-language Explicit Semantic Analysis (CL-ESA)

X

Alan Turing was conceived at Cheshire, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to India Vale, London, where Alan was born on 23 June 1912. He had an elder brother, John. His father's civil service career was still active, and during Alan's childhood years his parents travelled between England, India and Australia.

4

1

Turing's Father Julius Mathison Turing, ein britischer Statistiker in Cheshire, Indien, und dessen Frau Ethel wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrte er nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Vater zu diesem Zeitpunkt seines Vaters noch nicht beendet war, pendelte er zwischen Indien und England. In Indien ließ er aus Furcht vor dem Krieg in der

5

0

[Log in / create account](#)

[Anmelden / Benutzerkonto erstellen](#)

WIKIPEDIA
The Free Encyclopedia

Main page
Contents
Featured content
Current events
Random article
Donate to Wikipedia

Interaction
Toolbox
Print/export

Languages
العربية
বাংলা
မြန်မာဘာသာ
Deutsch
Eesti
Español
Français
한국어⁺
হিন্দী
Bahasa Indonesia

Reuse

From Wikipedia, the free encyclopedia

To **reuse** is to use an item more than once. This includes conventional reuse where the item is used again for the same function, and new-life reuse where it is used for a different function. In contrast, **recycling** is the breaking down of the used item into **raw materials** which are used to make new items. By taking useful products and exchanging them, without reprocessing, reuse help save time, money, energy, and resources. In broader economic terms, reuse offers quality products to people and organizations with limited means, while generating jobs and business activity that contribute to the economy.

Historically, financial motivation was one of the main drivers of reuse. In the developing world this driver can lead to very high levels of reuse, however rising wages and consequent consumer demand for the convenience of



3R Concepts

- Waste Disposal Hierarchy
 - Reduce
 - **Reuse**
 - Recycle
- Barter
- Dematerialization
- Downcycling
- Dumpster diving
- Ecodesign
- Ethical consumerism
- Freeganism
- Extended producer responsibility
- Industrial ecology
- Industrial metabolism
- Material flow analysis

Wikipedia
Die freie Enzyklopädie

Hauptseite
Über Wikipedia
Themenportale
Von A bis Z
Zufälliger Artikel

Mitmachen
Drucken/exportieren
Werkzeuge

In anderen Sprachen
العربية
বাংলা
မြန်မာဘာသာ
English
Español
Eesti
Suomi
Français
עברית
हिन्दी

Wiederverwendung

Wiederverwendung ist das Prinzip, Aufwand und Material einzusparen, indem ein an einer Stelle nicht mehr benötigter (und damit erneut verfügbar gewordener) Gegenstand an anderer Stelle eingesetzt wird. Durch diese Vorgehensweise erspart man die Vernichtung (auch Zerlegung oder Beseitigung) des nicht mehr benötigten Gegenstands und die Erstellung einer neuen Instanz. Im Speziellen kann es sich dabei handeln um:

- **Rekonditionierung (Technik)**, die Aufarbeitung von gebrauchten Produkten
- **Retrofit**, die Modernisierung oder der Ausbau bestehender Produktionsanlagen
- **Recycling**, die Verarbeitung von Abfall zu Rohstoffen
- **Wiederverwendbarkeit**, einmal geschriebene Programmodule auf universelle Einsetzbarkeit auszulegen

Die Wiederverwendung kann zusätzlichen Aufwand mit sich bringen: Eine Lagerung ist erforderlich, falls die Wiederverwendung nicht sofort möglich ist. Des Weiteren müssen während der Aufbereitung des Gegenstands eventuell vorhandene Gebrauchsspuren entfernt werden.

Weitere Wortbedeutung [Bearbeiten]

Beamte die das 131er-Gesetz von 1951 betrafen, durften ihre Amtsbezeichnung mit dem Zusatz „zur Wiederverwendung (z. Wv.)“ versehen.

Cross-language Explicit Semantic Analysis (CL-ESA)

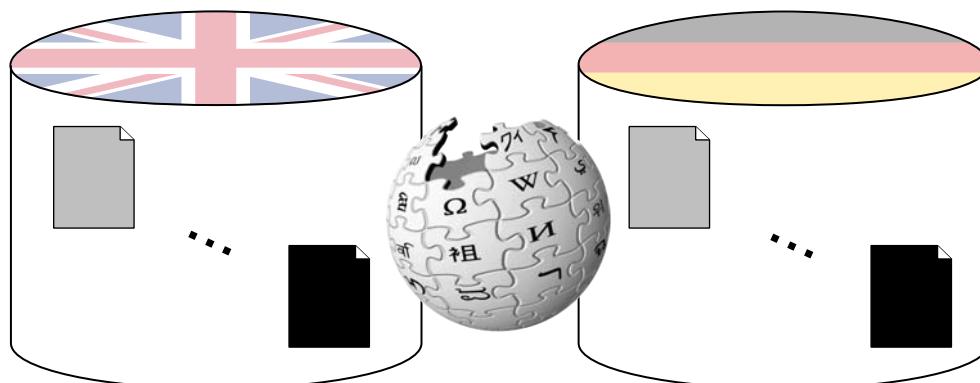
Alan Turing was conceived at Cheshire, Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to India Vale, London, where Alan was born on 23 June 1912. He had an elder brother, John. His father's civil service career was still active, and during ~~and~~ ^{his} childhood years his parents travelled between England, England and India, taking their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius. He was to later prominently display.

4
1



Turing's Father Julius Mathison Turing, ein britischer Statistiker in Cheshire, Indien, und dessen Frau Ethel wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrte er nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Vater erst seines Vaters reisen sich beendet war, pendelte er zwischen Indien und England. Seine Mutter ließ er aus Furcht vor dem Krieg in die Britische Kavallerie bei Freunden in England zurück. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Tinterns.

5
1
0



Cross-language Explicit Semantic Analysis (CL-ESA)

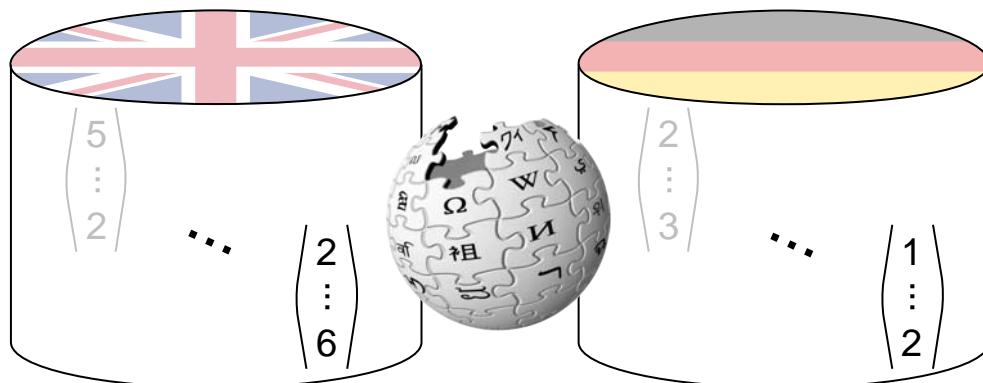
Alan Turing was conceived at Charsworth Orissa, India. His father was a member of the Indian Civil Service. He and his wife wanted Alan to be brought up in England, so they returned to India Vale, London, where Alan was born on 23 June 1912. He had an elder brother, John. His father's civil service career was still active, and during Alan's childhood years his parents travelled between England, India and England again, leaving their two sons to stay with a retired Army couple. Very early in life, Turing showed signs of the genius, he was to later prominently display.

4
1

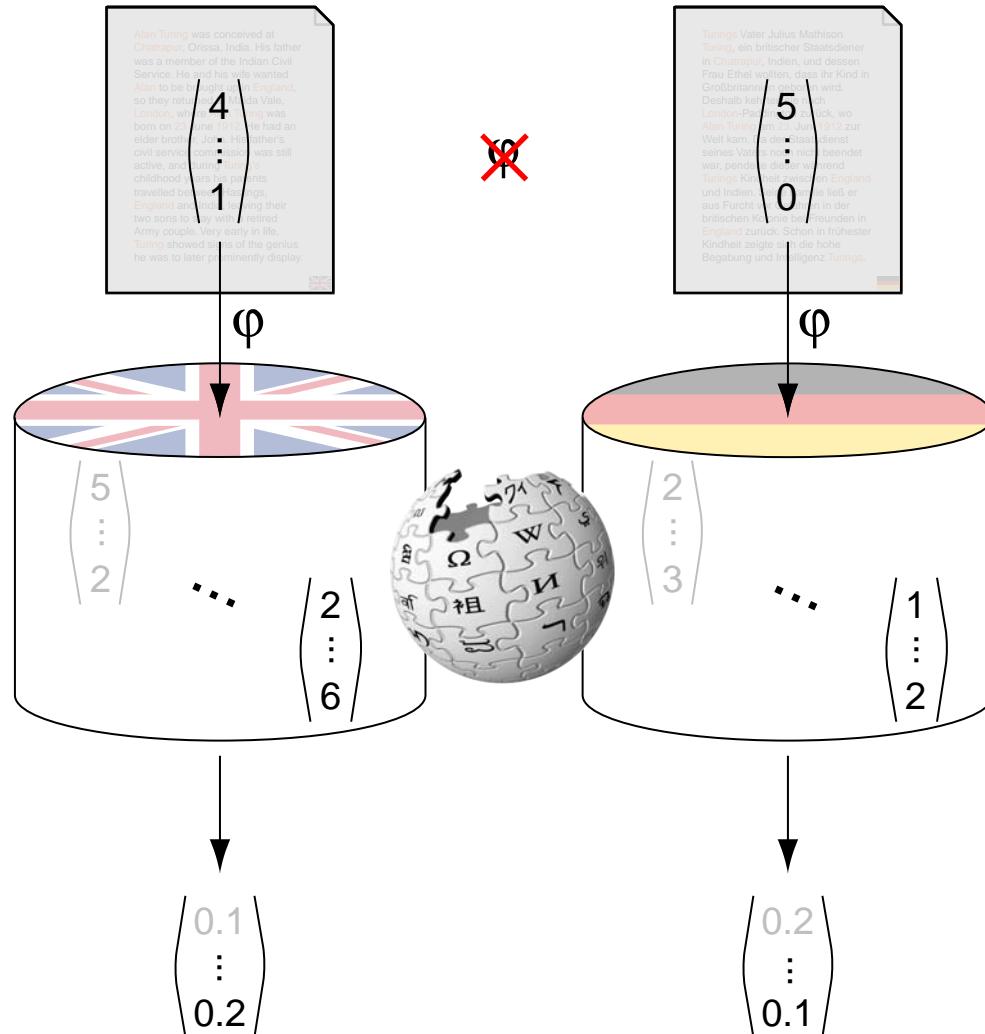


Turing's Father Julius Mathison Mathison, ein britischer Statistiker in Charsworth, Indien, und dessen Frau Ethel wollten, dass ihr Kind in Großbritannien geboren wird. Deshalb kehrte er nach London-Paddington zurück, wo Alan Turing am 23. Juni 1912 zur Welt kam. Da der Vater zuerst seines Vaters reisen sich beendet war, pendelte er zwischen Indien und England. In Indien ließ er aus Furcht vor dem Krieg in der Britischen Kavallerie bei Freunden in England zurück. Schon in frühester Kindheit zeigte sich die hohe Begabung und Intelligenz Tinterns.

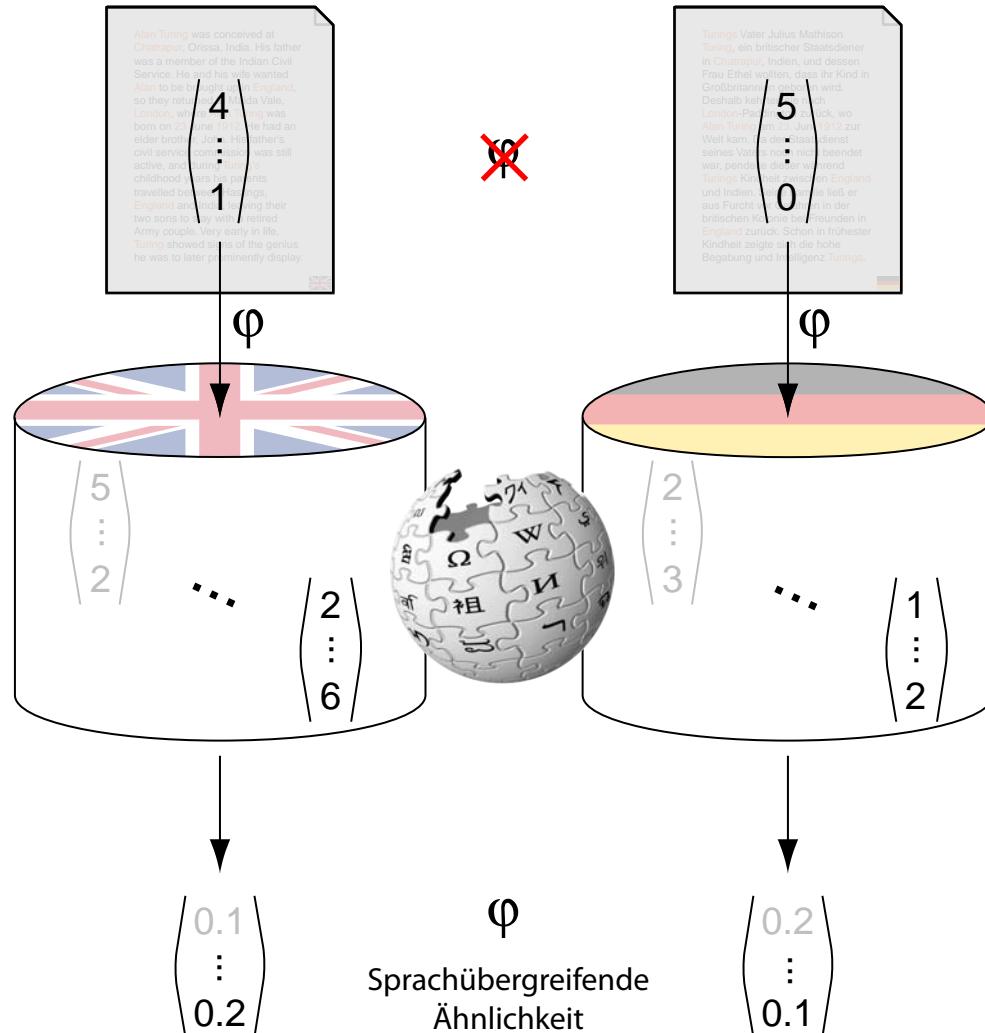
5
1
0



Cross-language Explicit Semantic Analysis (CL-ESA)



Cross-language Explicit Semantic Analysis (CL-ESA)

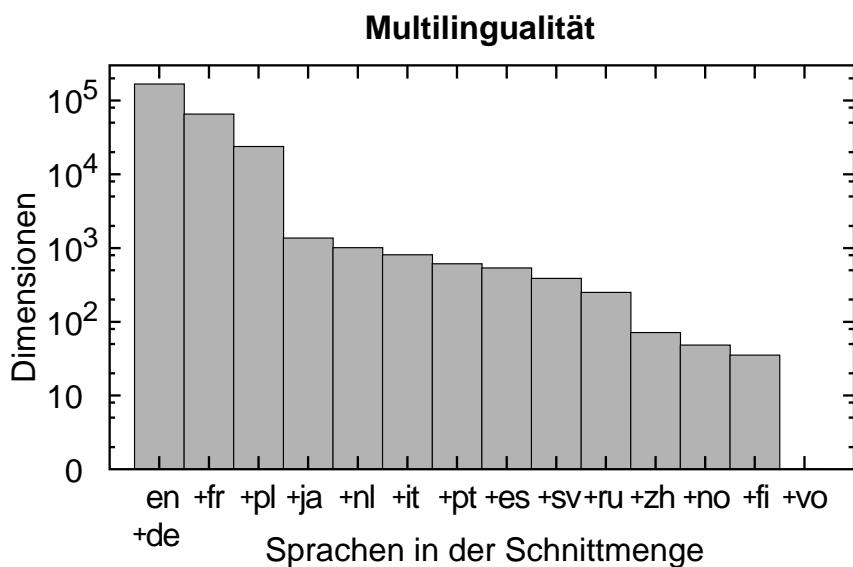
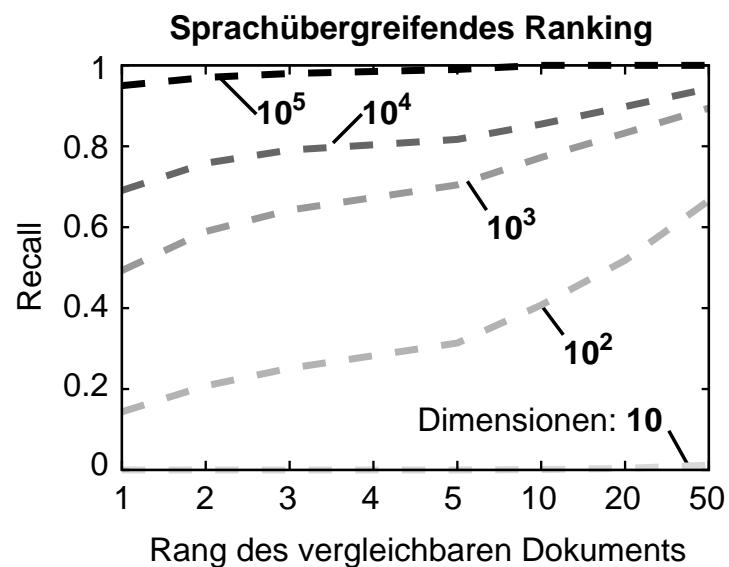


Cross-language Explicit Semantic Analysis (CL-ESA)

Experimente

1. Sprachübergreifendes Ranking
 2. Bilinguale Rangkorrelation
 3. Sprachübergreifende Ähnlichkeitsverteilung
 4. Tradeoff Effektivität und Effizienz (Dimensionalität)
 5. Multilingualität (Zahl gleichzeitig repräsentierbarer Sprachen)
 6. Laufzeit
- Vergleich mit zwei State-of-the-Art-Modellen
 - Verwendung zweier multilingualer Testkollektionen
 - Vergleich auf 6 Sprachpaarungen
 - > 100 Millionen Ähnlichkeiten berechnet

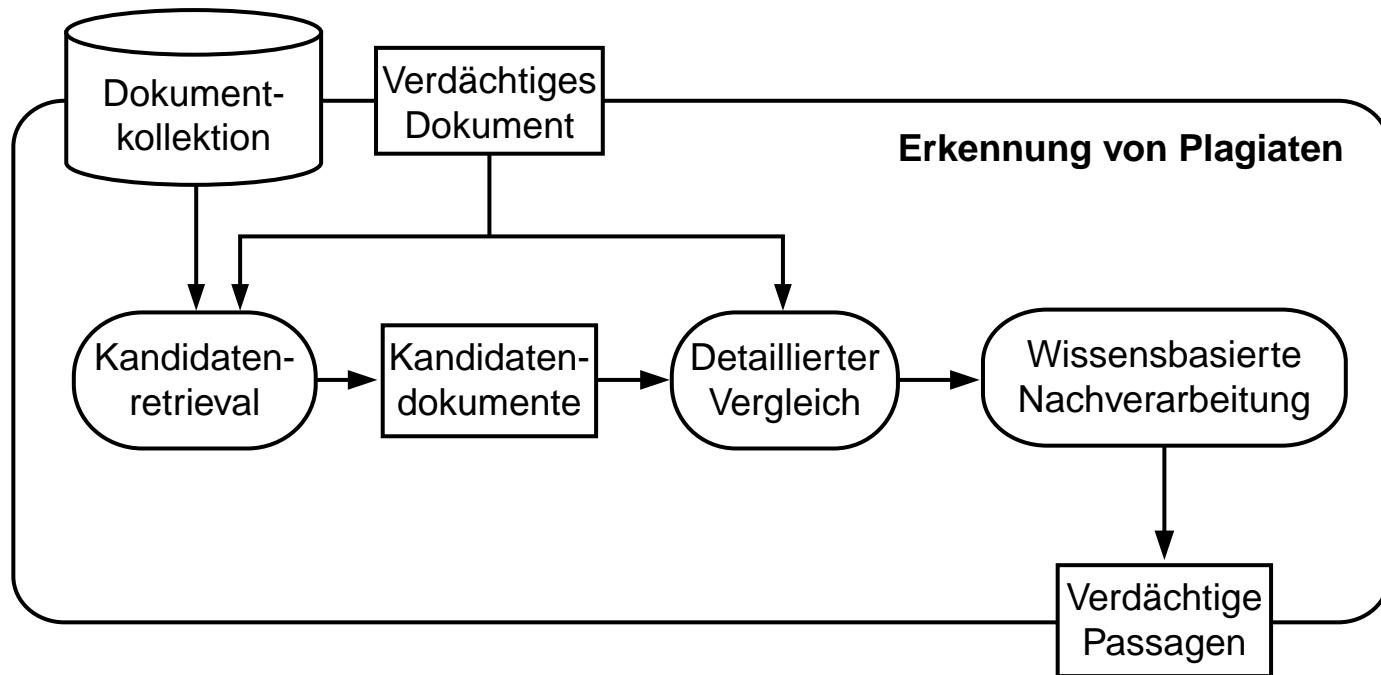
Cross-language Explicit Semantic Analysis (CL-ESA)



Wie Maschinen Plagiate erkennen

Wie Maschinen Plagiate erkennen

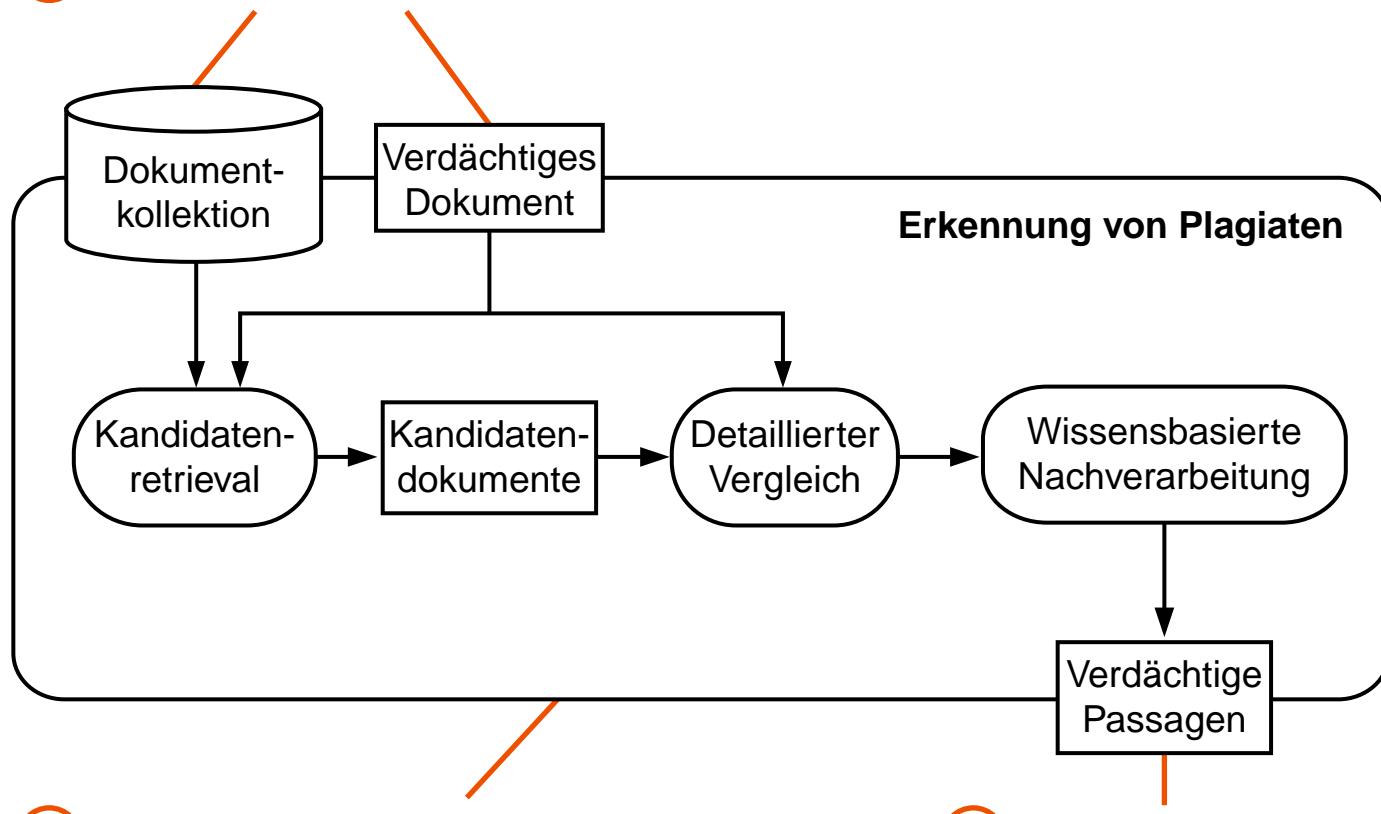
- Wie können sprachübergreifende Plagiate erkannt werden?
- Wie verlässlich sind Algorithmen zur Plagiatserkennung?



Wie Maschinen Plagiate erkennen

- Wie können sprachübergreifende Plagiate erkannt werden?
- Wie verlässlich sind Algorithmen zur Plagiatserkennung?

① Korpus von Plagiaten



③ Alternative Implementierungen

② Erfolgsmaße

Studie zur Evaluierung von Plagiatserkennungsalgorithmen

Evaluierungsaspekt	Text	Code	Evaluierungsaspekt	Text	Code		
① Korpusakquise							
Verfügbares Korpus	20%	18%	Precision, Recall	43%	18%		
Eigenes Korpus	80%	82%	Manuell, Ähnlichkeit	35%	69%		
Korpusgröße [# Dokumente]							
[1, 10)	11%	10%	Laufzeit	15%	1%		
[10, 10 ²)	19%	30%	Andere	7%	12%		
[10 ² , 10 ³)	38%	33%	③ Vergleichende Experimente				
[10 ³ , 10 ⁴)	8%	11%	Keine	46%	51%		
[10 ⁴ , 10 ⁵)	16%	4%	Parameter	19%	9%		
[10 ⁵ , 10 ⁶)	8%	0%	Andere Algorithmen	35%	40%		

- 205 Papiere wurden analysiert
- Ist es möglich, eine Trendwende herbeizuführen?



Internationaler Wettbewerb zur Plagiatserkennung

- Erste standardisierte Testumgebung
 - Ausgerichtet jährlich seit 2009
-
- ① Große neue Korpora von Plagiaten (PAN Plagiarism Corpus 2009-2012)
 - ② Maßgeschneiderte Erfolgsmaße (Plagdet, Precision, Recall, Granularity)
 - ③ 32 teilnehmende Forschergruppen (35 Anmeldungen für 2012)

Ziel:

- Eine möglichst große, repräsentative Auswahl von plagierten Dokumenten sowie den verwendeten Quelldokumenten.

Probleme:

- Reale Plagiatsfälle nicht im großen Maßstab verfügbar
- Abhängige Variablen unbekannt

Möglichkeiten:

- Plagiate automatisch generieren (seit 2009 im PAN Plagiatskorpus)
 - Plagiate halbautomatisch generieren (seit 2010 via Mechanical Turk)
 - Plagiate manuell erstellen (seit 2012 via oDesk)
 - Ähnliche Textwiederverwendungen anderer Domänen sammeln
 - Reale Plagiate suchen / sammeln (seit 2011 für deutsche Dissertationen)
- Crowdsourcing als Schlüssel für große Skalen, Realismus und Diversität

Zusammenfassung & Fazit

Sprachübergreifende Textähnlichkeit

- CL-ESA benötigt keine Wörterbücher, parallele Korpora, oder Übersetzer
- Vergleichbare Korpora sind für viele Sprachpaarungen leicht erstellbar

Evaluierung von Plagiatserkennungsverfahren

- Ergebnisse von PAN zeigen, dass noch viel Luft nach oben ist
- Das beste, was ein Plagiatserkenner in der Praxis leisten kann ist, das Durchkommen mit plumpen Plagiaten schwieriger zu machen
- Eigentlich werden nicht Plagiate, sondern bloß verdächtige Textwiederverwendungen erkannt

Wettbewerb zur Plagiatserkennung PAN

- Webseite: <http://pan.webis.de>
- Korpora: <http://www.webis.de/research/corpora>
- Community: <http://groups.google.com/group/pan-workshop-series>