37. Algorithmus der Woche
Fingerprinting

Autor
Martin Dietzfelbinger, Technische Universität Ilmenau

Alice und Bob sind dicke Freunde. Alice wohnt in Adelaide in Australien und Bob in Barnsley in (Groß-)Britannien. Sie telefonieren gerne miteinander, was aber ganz schön ins Geld geht, wenn es länger dauert. Die beiden haben sehr ähnliche Interessen; da ist es kein Zufall, dass sich beide ein Lexikon anschaffen.

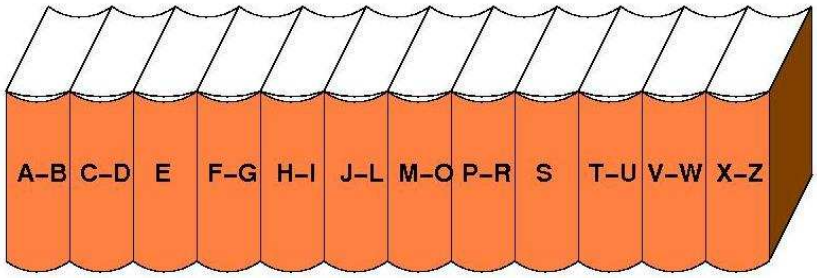

Sie erzählen sich am Telefon von ihrem Lexikonkauf. So ein Zufall! Das gleiche Lexikon! Alice stellt telefonisch eine leichte (oder doch nicht so leichte?) Frage: Steht in beiden Lexika derselbe Text? Sind sie wirklich Wort für Wort, Komma für Komma identisch?

Sogar wenn Alice und Bob feststellen, dass beide z.B. die 10. Auflage des Lexikons besitzen, muss das nicht unbedingt heißen, dass in dem in Australien gedruckten Exemplar wortwörtlich derselbe Text steht wie in dem in England gedruckten. Vielleicht wurden irgendwelche Druckfehler ausgebessert? Was tun? Alice könnte Bob ihr Lexikon vorlesen. Bob würde mitlesen und Wort für Wort vergleichen. Das würde theoretisch funktionieren, aber höllisch Telefongebühren kosten, denn …

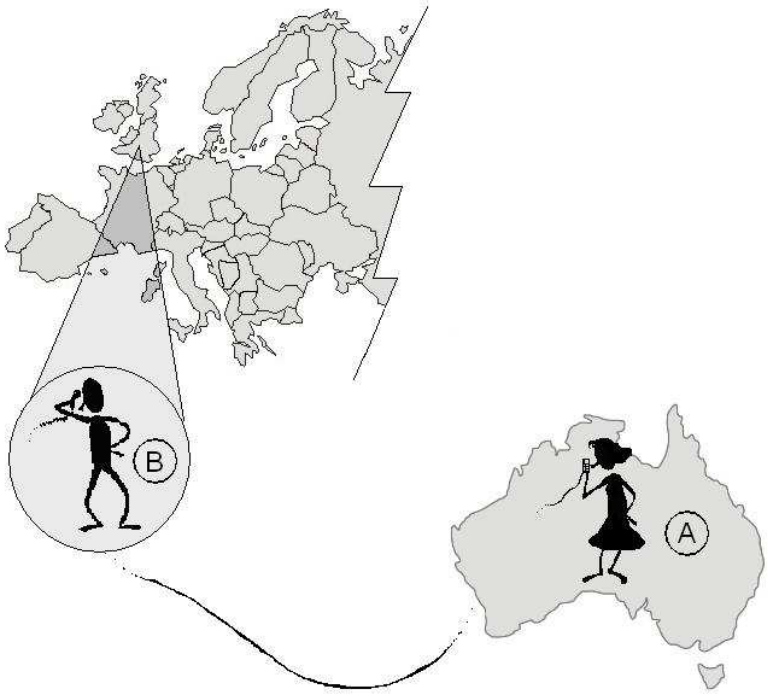

Alice und Bob haben ein **sehr dickes** Lexikon gewählt: 25 Bände, etwa 800 Seiten pro Band, etwa 2500 Schriftzeichen pro Seite: macht etwa 20000 Seiten und 50 Millionen Schriftzeichen. Wenn Alice für eine Seite nur 5 Minuten braucht, sind die beiden ohne Pause mehr als 80 Tage beschäftigt.

Wir können in einem Computer ein Schriftzeichen (auch die Kommas und Zwischenräume) mit einem Binärcode darstellen, zum Beispiel mit 8 Bits, d.h. 1 Byte, pro Zeichen. Macht für das Lexikon 50 Millionen Bytes, oder etwa 50 Megabytes (MB). Alice könnte nun natürlich ihr Lexikon in den Computer eintippen oder einscannen oder die Textkopie auf der mitgelieferten CD benutzen und Bob die Datei per Email schicken. Das finden wir aber gemogelt, und bestehen (im Jahr 2006 ein bisschen künstlich) darauf, dass Botschaften mündlich übermittelt werden, und dass Telefonieren Geld kostet. Computer darf man aber natürlich benutzen.

Die Frage ist also: Können Alice und Bob feststellen, ob die beiden Texte gleich sind, ohne sie Wort für Wort zu vergleichen?

Wer öfter große Dateien per Email verschickt oder auf seiner knallvollen Festplatte Platz schaffen musste, hat vielleicht schon einmal etwas von „Datenkompression“ gehört. Das sind Methoden, mit denen man Daten wie Texte oder Bilder „zusammenquetscht“, um Übertragungszeiten zu verkürzen und um Speicherplatz zu sparen. Alice und Bob könnten solche Methoden benutzen. Aber sogar wenn sie eine Komprimierung auf ein Fünftel der ursprünglichen Länge bewerkstelligen könnten, wären dies immer noch 10 Millionen Zeichen, die Alice übermitteln müsste. Das ist den beiden einfach zu viel.

Wie sollen Alice und Bob es anstellen, um mit noch weniger Kommunikation auszukommen?

Eine ganz einfache Beobachtung: Alice sollte zunächst die Buchstaben in ihrem Lexikon zählen. Diese Anzahl wollen wir n nennen. Alice sagt Bob, was n ist (das sind 8 Dezimalziffern, also kein Problem). Bob hat inzwischen die Buchstaben in seinem Lexikon gezählt, Resultat n'. Wenn n und n' verschieden sind, haben die Lexika verschiedene Texte, und wir sind fertig. (Wir wollen mal annehmen, dass Alice und Bob sich nicht verzählen.) Ab hier sind also die Texte, die wir vergleichen wollen, auf jeden Fall gleich lang.

Eine wie lange Nachricht muss Alice nun übermitteln?

Bevor wir diese Frage beantworten können, müssen wir etwas technischer werden und uns ein bisschen Handwerkszeug zurechtlegen. Wir haben schon gesagt, dass man Buchstaben im Computer mit Bitmustern

(Bytes) darstellt. Hier benutzen wir eine Standard-Darstellung, den ASCII-Code. In dieser Darstellung sehen `A`, `B`, `C` so aus: 01000001, 01000010, 01000011, und so weiter. Diese Bitmuster kann man auch als Zahlen auffassen, zum Beispiel:

`A`	`B`	`C`	...	`Z`	`a`	`b`	...	`z`
65	66	67	...	90	97	98	...	122

Auch die Satzzeichen bekommen Nummern, z.B. hat das Ausrufezeichen die Nummer 33 und ein Zwischenraum die Nummer 32. Mit 8 Bits bekommt man Zahlen zwischen 0 und 255. Der Text

```
Alice und Bob telefonieren.
```

wird, inklusive Zwischenräumen und Punkt, in die Folge

65 108 105 99 101 32 117 110 100 32 66 111 98 32 116 101 108 101 102 111 110 105 101 114 101 110 46

übersetzt, die wir mathematisch als

(65,108,105,99,101,32,117,110,100,32,66,111,98,32,116,101,108,101,102,111,110,105,101,114,101,110,46)

schreiben. Wir können uns nun also vorstellen, dass Alice ihr ganzes Lexikon in eine einzige lange Folge

$$T_A = (a_1, a_2, \ldots, a_{n-1}, a_n)$$

von Zahlen zwischen 0 und 255 übersetzt hat und dass Bob das gleiche mit seinem Lexikon gemacht hat:

$$T_B = (b_1, b_2, \ldots, b_{n-1}, b_n).$$

Dabei ist n ungefähr 50 Millionen.

So lange Folgen können wir auf dieser Webseite natürlich nicht aufschreiben. Wir nehmen als Beispiel erst einmal zwei Folgen der Länge $n = 8$: die Folge für „Adelaide“ (weil das auch ziemlich weit vorne im Lexikon steht):

$$T_{\mathrm{Ad}} = (a_1, a_2, \ldots, a_8) = (65, 100, 101, 108, 97, 105, 100, 101),$$

und die Folge für „Barnsley“:

$$T_{\mathrm{Ba}} = (b_1, b_2, \ldots, b_8) = (66, 97, 114, 110, 115, 108, 101, 121).$$

Nun müssen wir uns an einen Trick erinnern: „modulare Arithmetik“. (Siehe den 13. Algorithmus der Woche über „Fehlererkennende Codes“.) Das heißt, dass man ganze Zahlen nimmt und immer den Rest bei der Division durch m ausrechnet, bzw. zählt, wieviele Schritte man auf der Zahlengeraden nach links gehen muss, bis man auf ein Vielfaches von m trifft. Wenn zum Beispiel $m = 7$ ist, hat man $16 \bmod 7 = 2$ und $-4 \bmod 7 = 3$. In der folgenden Tabelle sind noch mehr Werte aufgeschrieben. Man erkennt das Muster: es geht immer im Kreis herum.

a	...	−4	−3	−2	−1	0	1	2	3	4	5	6	7	8	9	10	...
a mod **7**	...	3	4	5	6	0	1	2	3	4	5	6	0	1	2	3	...

Man kann Zahlen „modulo m“ auch addieren und multiplizieren. Das heißt: man addiert und multipliziert ganz normal und rechnet vom Ergebnis den Rest bei der Division durch m aus. Um sich die Arbeit zu erleichtern, darf man bei längeren Rechnungen auch unterwegs Zwischenergebnisse immer durch ihren Rest ersetzen.

Nun zurück zu unseren Beispieltexten T_{Ad} und T_{Ba}. Wir legen eine Zahl m fest. Später werden wir sehen, dass m eine Primzahl sein sollte, die größer als 255 und größer als n ist, vielleicht etwa so groß wie $2n$ oder $10n$.

Für unser Beispiel wählen wir $m = 17$.

Für $r = 0, 1, 2, \ldots, m-1$ und einen Text $T = (a_1, a_2, \ldots, a_{n-1}, a_n)$ sehen wir die folgende Zahl an:

$$\mathrm{FP}(T, r) = (a_1 \cdot r^n + a_2 \cdot r^{n-1} + \cdots + a_{n-1} \cdot r^2 + a_n \cdot r) \bmod m.$$

Zum Beispiel bekommen wir für T_{Ad} und $r = 3$:

$$\mathrm{FP}(T_{\mathrm{Ad}}, 3) = (65 \cdot 3^8 + 100 \cdot 3^7 + 101 \cdot 3^6 + 108 \cdot 3^5 + 97 \cdot 3^4 + 105 \cdot 3^3 + 100 \cdot 3^2 + 101 \cdot 3) \bmod 17.$$

Wir nennen $\mathrm{FP}(T, r)$ einen „Fingerabdruck“ (engl.: „**F**inger**p**rint“) für den Text $T = (a_1, a_2, \ldots, a_n)$ (mit r berechnet), weil in der Zahl $\mathrm{FP}(T, r)$ auf kleinem Raum eine gewisse Information über T gespeichert ist, die wir vielleicht nutzen können, um T von anderen Texten zu unterscheiden, so wie ein kleiner Fingerabdruck genügt, um Menschen zu unterscheiden. Ein ganz primitiver „Fingerabdruck“ ist natürlich auch die Länge n des Textes.

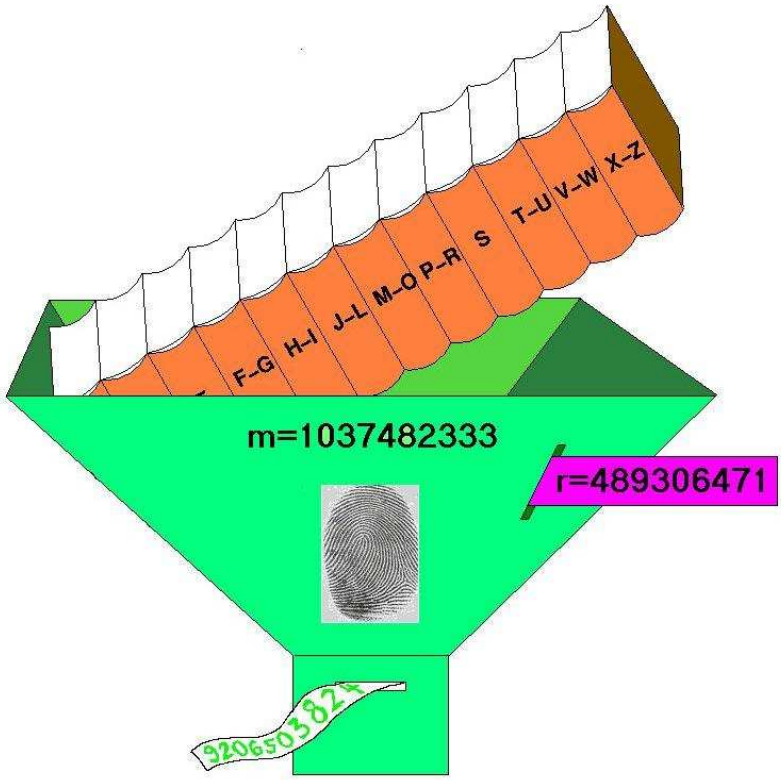

Die Berechnung von $\mathrm{FP}(T, r)$ sieht, besonders für die langen Texte, die uns eigentlich interessieren, ziemlich gefährlich und teuer aus, weil durch die hohen Potenzen riesengroße Zahlen entstehen. Hier hilft ein recht einfacher Trick, nämlich Umklammern:

$$\mathrm{FP}(T, r) = ((((\cdots(((a_1 \cdot r) + a_2) \cdot r) + \cdots) \cdot r + a_{n-1}) \cdot r + a_n) \cdot r) \bmod m.$$

Wenn man diesen Ausdruck wie üblich von innen nach außen fortschreitend ausrechnet, und „unterwegs“ bei jedem Zwischenergebnis den Rest „modulo m“ bildet, kann man die Zwischenergebnisse klein halten, ganz egal wie groß n ist. Im Beispiel, mit $r = 3$, ergibt sich:

	Werte	Zwischenergebnis
a_1	65	$(65 \cdot 3) \bmod 17 = (14 \cdot 3) \bmod 17 = 8$
a_2	100	$((8+100) \cdot 3) \bmod 17 = (6 \cdot 3) \bmod 17 = 1$
a_3	101	$((1+101) \cdot 3) \bmod 17 = (0 \cdot 3) \bmod 17 = 0$
a_4	108	$((0+108) \cdot 3) \bmod 17 = (6 \cdot 3) \bmod 17 = 1$
a_5	97	$((1+97) \cdot 3) \bmod 17 = (13 \cdot 3) \bmod 17 = 5$
a_6	105	$((5+105) \cdot 3) \bmod 17 = (8 \cdot 3) \bmod 17 = 7$
a_7	100	$((7+100) \cdot 3) \bmod 17 = (5 \cdot 3) \bmod 17 = 15$
a_8	101	$((15+101) \cdot 3) \bmod 17 = (14 \cdot 3) \bmod 17 = 8$

Also ist $\mathrm{FP}(T_{\mathrm{Ad}}, 3) = 8$.

Natürlicherweise ist der Fingerabdruck selber immer ein Rest modulo m, also eine Zahl zwischen 0 und $m-1$, und auch die Zwischenresultate bei der Berechnung sind nicht allzu groß (nicht größer als m^2).

Wie rechnet man also einen Fingerabdruck $\mathrm{FP}(T, r)$ aus?

```
Algorithmus FP(T, r)
 1  begin
 2  fp := (a_1 · r) mod m;
 3  for i from 2 to n do
 4      fp := ((fp + a_i) · r) mod m;
 5  return fp
 6  end
```

Mit diesem Programm rechnen wir spaßeshalber einmal alle $m = 17$ Fingerabdrücke für T_{Ad} und für T_{Ba} aus.

r	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
$\mathrm{FP}(\mathbf{T}_{\mathrm{Ad}}, \mathbf{r})$	0	12	7	8	11	14	15	5	11	1	2	12	13	13	6	6	0
$\mathrm{FP}(\mathbf{T}_{\mathrm{Ba}}, \mathbf{r})$	0	16	9	2	2	6	14	3	11	12	2	10	11	15	2	10	11

(Alice könnte die erste Zeile ausrechnen, Bob die zweite.) Wir vergleichen die Werte für T_{Ad} und T_{Ba}. Bei $r = 0$ steht da in beiden Zeilen 0, ach ja, ist ja klar, im Algorithmus FP ist die letzte Aktion eine Multiplikation mit r, und wenn $r = 0$ ist … Ein Fingerabdruck mit $r = 0$ ist also langweilig. Sonst sehen die Zahlen ziemlich wirr aus. Wir vergleichen übereinander stehende Zahlen. Bei $r = 3$ (unser Beispiel) ist $\mathrm{FP}(T_{\mathrm{Ad}}, r) = 8$ und $\mathrm{FP}(T_{\mathrm{Ba}}, r) = 2$. Der Fingerabdruck mit $r = 3$ würde also helfen zu sagen, dass die Texte verschieden sind. Bei $r = 8$ und bei $r = 10$ kommt aber derselbe Wert heraus (11 bzw. 2), diese r's helfen also nicht.

Jetzt kommt die entscheidende Idee. Nehmen wir einmal an, Alice und Bob machen sich überhaupt nicht die Mühe, **alle** Werte in der Tabelle auszurechnen. (Bei größeren n und m geht das sowieso aus Zeitgründen nicht.) Alice wählt aber eine Zahl r zwischen 1 und $m-1$ **zufällig**. Sie könnte zum Beispiel wiederholt ein „Glücksrad“ drehen, dessen Rand in zehn gleichgroße Teile unterteilt ist, um die Dezimalziffern von r zu bestimmen.

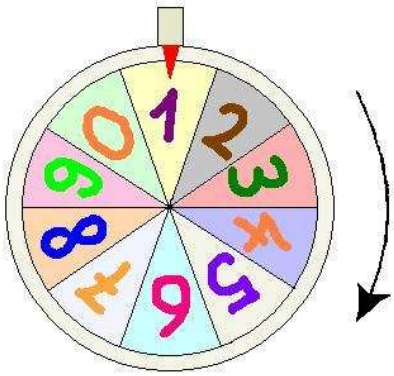

Sie ruft Bob an und sagt ihm, welches r sie gewählt hat. Das sind nur wenige Dezimalziffern. Anschließend rechnet Alice $\mathrm{FP}(T_A, r)$ aus – das lässt sie ihren Computer machen – und gleichzeitig rechnet Bob $\mathrm{FP}(T_B, r)$ aus. Das dauert möglicherweise eine Weile, kostet aber keine Telefongebühren. Dann ruft Alice Bob erneut an und nennt ihm „ihren“ Fingerabdruck $\mathrm{FP}(T_A, r)$. Nun gibt es verschiedene Möglichkeiten.

1. Fall: Die Texte T_A und T_B sind gleich. Dann erhalten Alice und Bob **immer** die gleichen Resultate, ganz egal, welches r Alice gewählt hat.

2. Fall: Die Texte T_A und T_B sind verschieden (im Beispiel „Adelaide“ und „Barnsley“ bei $m = 17$).

   – Wenn Alice eine Zahl r mit $\mathrm{FP}(T_A, r) = \mathrm{FP}(T_B, r)$ gewählt hat (im Beispiel: $r = 8$ oder $r = 10$), dann bekommt Bob denselben Fingerabdruck wie Alice heraus, und es sieht für die beiden so aus, als könnten die Texte gleich sein.

   – Wenn Alice eine Zahl r mit $\mathrm{FP}(T_A, r) \neq \mathrm{FP}(T_B, r)$ gewählt hat (im Beispiel: eine der anderen 14 Zahlen), dann bekommt Bob einen anderen Fingerabdruck heraus und er kann Alice mitteilen, dass die Texte auf jeden Fall verschieden sind.

In unserem kleinen Beispiel ist die Chance, dass der Unterschied gefunden wird, 14 : 16, also 87,5 Prozent.

Wie stehen die Chancen, einen Unterschied zu finden, im allgemeinen Fall?

Man kann beweisen (tatsächlich ist das schon seit mehreren hundert Jahren bekannt), dass folgendes passiert:

Fingerprinting-Satz:
Wenn T_A und T_B verschiedene Texte (Zahlenfolgen) der Länge n sind, und wenn m eine Primzahl ist, die größer ist als die größte Zahl in T_A und T_B, dann können von den m Zahlenpaaren

$$\mathrm{FP}(T_A, r), \mathrm{FP}(T_B, r), \quad r = 0, 1, \ldots, m-1,$$

höchstens n viele aus gleichen Zahlen bestehen.

Dieser Satz ist eine der einfacheren der vielen wunderbaren Eigenschaften, die Primzahlen haben. (Wer mehr darüber wissen will, warum das so ist, möge sich die Zusatzinformationen des Autors, welche unter „Weiterführende Materialien“ zu finden sind, ansehen.)

Für unser Beispiel mit $n = 8$ heißt das: Ganz egal wie T_A und T_B aussehen: wenn sie verschieden sind, gibt es in unserer Tabelle nie mehr als 7 Werte $r \neq 0$, die Alice und Bob zum selben Ergebnis führen. Die Chance, dass der Unterschied gefunden wird, ist also immer mindestens 9:16, also mehr als 50 Prozent.

Nun kehren wir zur Anfangssituation zurück: $n \approx 50$ Millionen. Damit jetzt etwas Vernünftiges herauskommt, müssen Alice und Bob m um einiges größer als n wählen, sagen wir: m ist eine Primzahl etwas größer als 1 Milliarde, z.B. $m = 1037482333$. Für so große n und m können und wollen wir die Tabelle der $\mathrm{FP}(T,r)$-Werte bestimmt nicht mehr aufschreiben. Dennoch können wir sagen: Unter den $m-1$ Spalten gibt es höchstens n viele, wo die Werte übereinstimmen. Also: Wenn Alice r zwischen 1 und $m-1$ zufällig wählt und Alice und Bob rechnen und sich Zahlen und Fingerabdrücke mitteilen wie vorher, dann ist die Chance, dass sie den Unterschied zwischen verschiedenen Texten T_A und T_B entlarven, mindestens

$$\frac{(m-1)-(n-1)}{m-1} \approx \frac{1000000000-50000000}{1000000000} = 0{,}95,$$

also 95 Prozent.

Alice und Bob müssen zwar viel rechnen – das lassen sie ihre Computer machen – , aber sie müssen nicht viel Information austauschen: Alice muss Bob die Zahl n (8 Ziffern) und die Primzahl m nennen (10 Ziffern), und sie muss ihm die beiden Zahlen r und $\mathrm{FP}(T_A,r)$ vorlesen (20 Ziffern).

Alice muss Bob weniger als **40 Ziffern** mitteilen!

Wenn man mit einer Chance auf Entlarvung von unterschiedlichen Texten von 95 Prozent nicht zufrieden ist, gibt es eine auch nicht allzu teure Verbesserungsmöglichkeit: Alice wählt **zwei** Zahlen r_1 und r_2 zufällig und nennt Bob diese beiden und die Werte $\mathrm{FP}(T_A,r_1)$ und $\mathrm{FP}(T_A,r_2)$. Bob erklärt die beiden Texte für gleich (wobei er sich irren kann), wenn für T_B bei r_1 und r_2 dieselben Zahlen herauskommen. Die Chance, dass die beiden hier irrtümlich zwei verschiedene Texte für gleich halten, ist höchstens

$$\frac{(n-1)^2}{(m-1)^2} < \left(\frac{n}{m}\right)^2 \approx \frac{50000000^2}{1000000000^2} = 0{,}0025,$$

die Chance, den Unterschied zu entdecken, ist also 99,75 Prozent. Wenn man gar drei Zahlenpaare (insgesamt weniger als 80 Ziffern) schickt, fällt die Wahrscheinlichkeit, sich zu irren, auf höchstens $(n^3/m^3) \approx 0{,}000125$ oder 0,0125 Prozent; die Entlarvungschance steigt auf 99,9875 Prozent.

Wir fassen das Rechen- und Kommunikationsverfahren nochmals zusammen. Da es um eine Kombination von Berechnungen und Kommunikation geht, spricht man nicht von einem Algorithmus, sondern von einem „Protokoll“ (im Sinne einer Vorschrift darüber, wie sich die Beteiligten verhalten sollen).

Protokoll TEXTVERGLEICH MIT FINGERPRINTING
Alice hat Zahlenfolge $T_A = (a_1,\ldots,a_n)$ mit Ziffern zwischen 0 und $d-1$.
Bob hat Zahlenfolge $T_B = (b_1,\ldots,b_{n'})$ mit Ziffern zwischen 0 und $d-1$.

1. Alice sagt Bob, was n ist. Wenn $n \neq n'$ ist, sagt Bob „ungleich“, und STOP.
2. Alice und Bob einigen sich auf eine Wiederholungsanzahl k.
3. Alice sucht eine Primzahl m, die größer als d und $10n$ ist.
   Sie wählt k Zahlen $r_1,\ldots,r_k$ zwischen 1 und $m-1$ zufällig,
   und nennt Bob die Zahlen m und $r_1,\ldots,r_k$.
4. Alice berechnet $\mathrm{FP}(T_A,r_1),\ldots,\mathrm{FP}(T_A,r_k)$.
   (Schlauerweise ändert sie dazu den Algorithmus $\mathrm{FP}(T,r)$ so ab, dass sie mit *einem* Durchlauf durch den Text T_A alle k Resultate berechnet.)
5. Bob berechnet $\mathrm{FP}(T_B,r_1),\ldots,\mathrm{FP}(T_B,r_k)$.
6. Alice übermittelt Bob ihre k Resultate.
7. Bob vergleicht mit seinen k Werten.
   Wenn es Unterschiede gibt, sagt er „ungleich“, und STOP.
   Wenn alle Werte gleich sind, sagt er „kein Unterschied zu sehen“, und STOP.

Wenn man den „Fingerprinting-Satz“ benutzt und genauso wie oben argumentiert, nur etwas allgemeiner, erkennt man, dass man folgendes Verhalten garantieren kann:

- Wenn Alice und Bob denselben Text haben, ist das Ergebnis immer „kein Unterschied zu sehen“.
- Wenn Alice und Bob verschiedene Texte haben, ist die Wahrscheinlichkeit, dass sie das (unerwünschte) Resultat „kein Unterschied zu sehen“ bekommen, höchstens

$$\frac{n^k}{m^k} = \left(\frac{n}{m}\right)^k, \text{ also } \leq \frac{1}{10^k}.$$

  Mit einer passenden Wahl von k können die beiden die Irrtumswahrscheinlichkeit so winzig einstellen, wie sie möchten.
- Wenn $m \approx 10n$ ist, und n genau l Dezimalziffern hat, muss Alice nicht mehr als $(l+1)\cdot(2+2k)$ Ziffern übermitteln.
  (Es ist erstaunlich, wie gutmütig diese Formel auf eine Vergrößerung der Datenmenge reagiert: Wenn wir einen 10-mal so langen Text zu vergleichen haben, vergrößert sich die Anzahl der zu schickenden Ziffern nur um $2k$.)

Fazit:

- Wenn man beim Textvergleich absolute Sicherheit haben will, kann man ein Verfahren zur Datenkompression benutzen, spart aber bei gewöhnlichen Texten nicht mehr als einen Faktor 5 ein.
- Wenn man damit leben kann, dass es eine kleine Wahrscheinlichkeit dafür gibt, dass man verschiedene Texte irrtümlicherweise für gleich hält, dann kann man ein Fingerabdruck-Verfahren benutzen. Dieses verkürzt die zu übermittelnden Botschaften dramatisch.
- Die Irrtumswahrscheinlichkeit ist höchstens $\left(\frac{n}{m}\right)^k$ bei der Benutzung von k Fingerabdrücken. Man muss dann $(2+2k)$ Zahlen übermitteln, die höchstens so groß wie m sind.
- Die Verwendung von Zufall in Algorithmen und Kommunikationsprotokollen kann zu wesentlichen Einsparungen führen, wenn man bereit ist, in Kauf zu nehmen, dass eventuell ein falsches Ergebnis auftritt – mit einer kleinen Wahrscheinlichkeit.
- Algorithmen oder Protokolle, die manche Entscheidungen oder Auswahlen zufällig treffen, heißen „randomisiert“. (Von englisch „at random“ = zufällig).

(Fast) die Wahrheit:

Dass Alice und Bob einfach nur Freunde sind, war natürlich gelogen. In Wirklichkeit handelt es sich bei Alice um eine Industriespionin im Land A, bei Bob um ihren Kontaktmann im Land B. Die beiden wollen das Lexikon für ein Chiffrierverfahren benutzen, um Nachrichten abhörsicher zu übermitteln. Dabei ist es von äußerster Wichtigkeit, dass beide Texte Wort für Wort übereinstimmen. Das Übermitteln per email ist zu riskant: jemand könnte mithören. Mit einer Irrtumswahrscheinlichkeit von 0,0125 Prozent können die beiden gut leben, angesichts dessen, was beim Spionieren sonst noch alles schief gehen kann ...

Andere Anwendungen:

Das Fingerprinting-Verfahren zum Textvergleich kann man immer anwenden, wenn Rechenzeit zum Durcharbeiten der Texte vorhanden, aber Kommunikation teuer oder unsicher ist. Man könnte an den Abgleich der Inhalte von Kopien von Datenbanken nach einer Reihe von Updates denken oder an die regelmäßige

Überprüfung, ob die Daten in einem Computer in einer Raumsonde nach Änderungen noch (wie vorgesehen) exakt mit denen des Zwillingscomputers auf der Erde übereinstimmen. Auch zur Textsuche kann man das Fingerprint-Prinzip benutzen; dies liefert ein ganz anderes Verfahren als das im 30. Algorithmus der Woche (Boyer-Moore-Horspool-Algorithmus).

Autoren:

- Prof. Dr. Martin Dietzfelbinger
  `http://www.tu-ilmenau.de/fakia/Prof-Dr-USA-Marti.md.0.html`
  (Grafik unter Mitwirkung von J. D.)

Weiterführende Materialien:

- Zusätzliche Informationen des Autors
  `http://www.tu-ilmenau.de/fakia/Fachgebiet_Komplexit.749.0.html`

Externe Links:

- Wikipedia: Beschreibung des ASCII-Codes, mit Tabellen
  `http://de.wikipedia.org/wiki/ASCII`
- Wikipedia: Datenkompression
  `http://de.wikipedia.org/wiki/Datenkompression`