Steganographie

Ingo Blechschmidt,
Michael Hartmann

LUGA

4. Oktober 2006

Inhalt

Was ist Steganographie?

Definition

Steganographie ist die Wissenschaft der verborgenen Übermittlung von Informationen.

Einsatzgebiete:

- Sprache
- Digitale Medien
- Sport
- Kopierschutz

Beispiele für Steganographie

- Handzeichen beim Volleyball und Fußball
- Einsagen bei Ausfragen
- Versteckte Daten in Bildern, Audio- und Videodateien
- Umgehen von Servereinschränkungen (versteckte MP3 in Bildern)
- Passiver Kopierschutz → Wasserzeichen
- Verfassen von Briefen mit „Geheimtinte“

Historische Anwendungen

- Demeratus' Warnung an Sparta vor Angriff der Xerer
- Tätowierung von kahlrasierten Köpfen
- microdots: winzige Punkte, denen man keine Beachtung schenkt (1941 in Deutschland erfunden)
- Verbot von Postsendungen mit u.a. Schachaufgaben, Kreuzworträtseln, Zeitungsausschnitten, Strickmuster in den USA und England während des Zweiten Weltkriegs

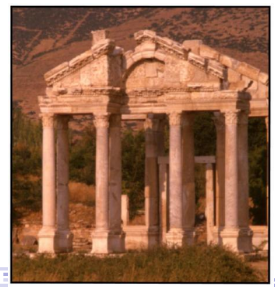

Abgrenzung zur Verschlüsselung

- Erregung von Verdacht durch verschlüsselte Nachrichten
- Verheimlichung von Informationsübermittlung durch Steganographie
- Steganographie kaum erkennbar
- Einfache bis sehr komplexe steganographische Algorithmen

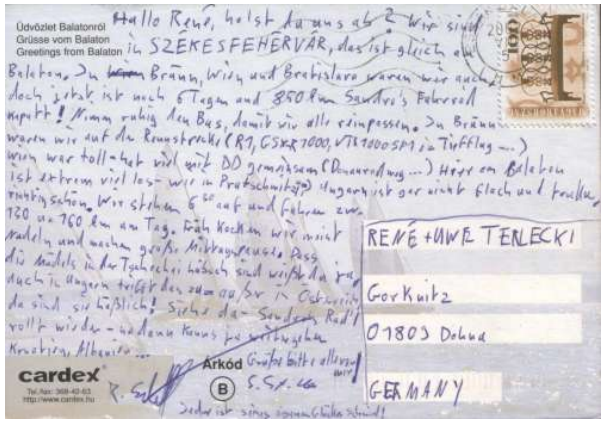

Mathematischer Hintergrund

Informationsgehalt eines Zeichens

$$I(x) := -\log_2 P(x); \qquad [1\,\text{bit}]$$

Entropie: Zu erwartender Informationsgehalt

$$E(I) := \sum_{x \in \Sigma} P(x) \cdot I(x);$$

x: ein bestimmtes Zeichen

Σ: Menge aller vorkommenden Zeichen

$P(x)$: Wahrscheinlichkeit des Auftretens von x

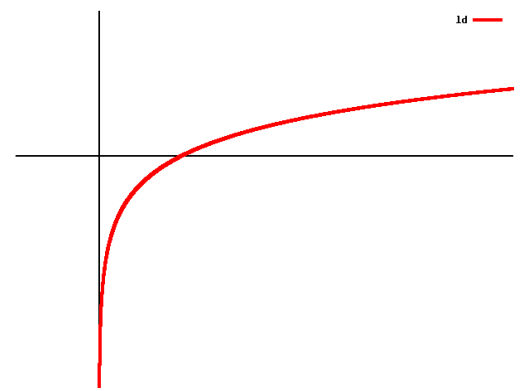

Beispiel

Definitionen

$$\begin{aligned} I(x) &:= -\log_2 P(x); \\ E(I) &:= \sum_{x \in \Sigma} P(x) \cdot I(x); \end{aligned}$$

$$\begin{aligned} M &= (a, l, l, e, s); \\ \Sigma &= \{a, e, l, s\}; \end{aligned}$$

$$\begin{aligned} I(a) = I(e) = I(s) &= -\log_2 \tfrac{1}{5} \approx 2{,}32\,\text{bit}; \\ I(l) &= -\log_2 \tfrac{2}{5} \approx 1{,}32\,\text{bit}; \end{aligned}$$

$$E(I) \approx 3 \cdot \frac{1}{5} \cdot 2{,}32\,\text{bit} + \frac{1}{5} \cdot 1{,}32\,\text{bit} \approx 1{,}67\,\text{bit};$$

Eigenschaften der Entropie

- Je seltener ein Zeichen, desto höherer Informationsgehalt
- Spezialfall bei gleicher Häufigkeit aller Zeichen:
  $P(x_1) = P(x_2) = \cdots = P(x_n) =: p$
  $I(x_1) = I(x_2) = \cdots = I(x_n) = -\log_2 p =: i$
  $E(I) = i$

  Beispiel:
  $M = (1, 2, 3, 4, 1, 2, 3, 4, 1, 2, 3, 4)$;
  $p = \frac{1}{4}$;
  $E(I) = i = -\log_2 \frac{1}{4} = 2\,\text{bit}$;
- Maximale Entropie bei $\Sigma = \{0, 1\}^8$:
  $E(I) = 8\,\text{bit}$;

Praktische Entropiebestimmung

Live-Demo

Praktische Entropiebestimmung

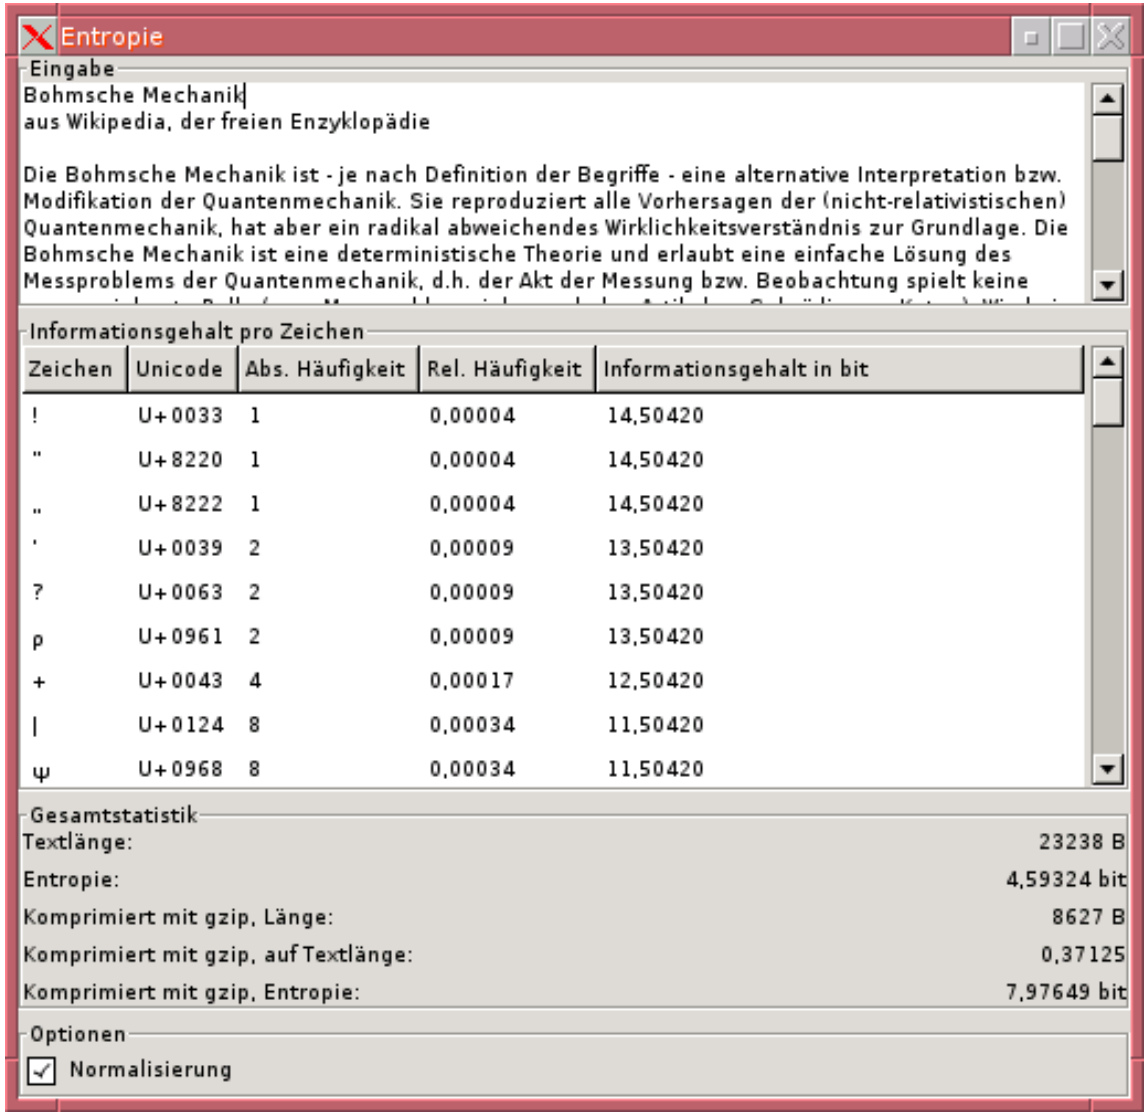

Praktische Entropiebestimmung

- Beispielimplementierung `entropy.pl` zur Bestimmung von Informationsgehalt und Entropie
- Aufruf mit:

  `$ perl entropy.pl` oder:

  `$ perl entropy.pl corpus.txt`
- Benötigte nicht-Standard-Perl-Module: Compress::Zlib, Gtk2
- Installation über:

  `# apt-get install libcompress-zlib-perl libgtk2-perl` oder:

```
# perl -MCPAN -eshell
> install Compress::Zlib
> install Gtk2
```

Verzeichnisse als Trägermedium

```
$ ls -l
-rw-rw-rw- 1 user group 32372 01-Mathematik.txt
-rw-rw-rw- 1 user group 63814 02-Physik.txt
-rw-rw-rw- 1 user group  4831 03-Chemie.txt
-rw-rw-rw- 1 user group  1129 04-Biologie.txt
-rw-rw-rw- 1 user group 10037 05-Musik.txt
-rw-rw-rw- 1 user group 57001 06-Kunst.txt
```

Verzeichnisse als Trägermedium

```
$ ls -l
-rw-rw-rw- 1 user group 32372 01-Mathematik.txt
-rw-rw-rw- 1 user group 63814 02-Physik.txt
-rw-rw-rw- 1 user group  4831 03-Chemie.txt
-rw-rw-rw- 1 user group  1129 04-Biologie.txt
-rw-rw-rw- 1 user group 10037 05-Musik.txt
-rw-rw-rw- 1 user group 57001 06-Kunst.txt
```

Text als Trägermedium

```
Linux ist ein freies und plattformübergreifendes Betriebssystem, das
UNIX ähnlich ist. Schon bald nach Beginn der Entwicklung liefen viele
GNU-Tools, beispielsweise cat, echo, bash uvm. Nach kurzer Zeit wurde
auch ein Maskottchen für das noch junge System gefunden: ein Pinguin.
```

Text als Trägermedium

Linux ist ein freies und plattformübergreifendes Betriebssystem, das
UNIX ähnlich ist. Schon bald nach Beginn der Entwicklung liefen viele
GNU-Tools, beispielsweise cat, echo, bash uvm. Nach kurzer Zeit wurde
auch ein Maskottchen für das noch junge System gefunden: ein Pinguin.

- Relativ einfach zum Lesen und Erstellen
- Viele Algorithmen denkbar
- Kaum nachvollziehbar

Bilder als Trägermedium

- Verbergen von Daten durch Veränderung von Farben oder Verzerrung
- Farbänderung:
  Nutzung der Least Significant Bits (LSB) als Träger → minimale (kaum wahrnehmbare) Veränderung des Bildes

  $10001010_2 (= 1 \cdot 2^7 + 1 \cdot 2^3 + 1 \cdot 2^1 = 138) \rightarrow$
  $10001011_2 (= 1 \cdot 2^7 + 1 \cdot 2^3 + 1 \cdot 2^1 + 1 \cdot 2^0 = 139)$
- Veränderung der LSBs prinzipiell auch bei Audio-Dateien möglich
- Verzerren:
  Geringfügige, systematische Verzerrung abhängig von den zu versteckenden Daten

Lena, Original

Lena, steganographisch verändert

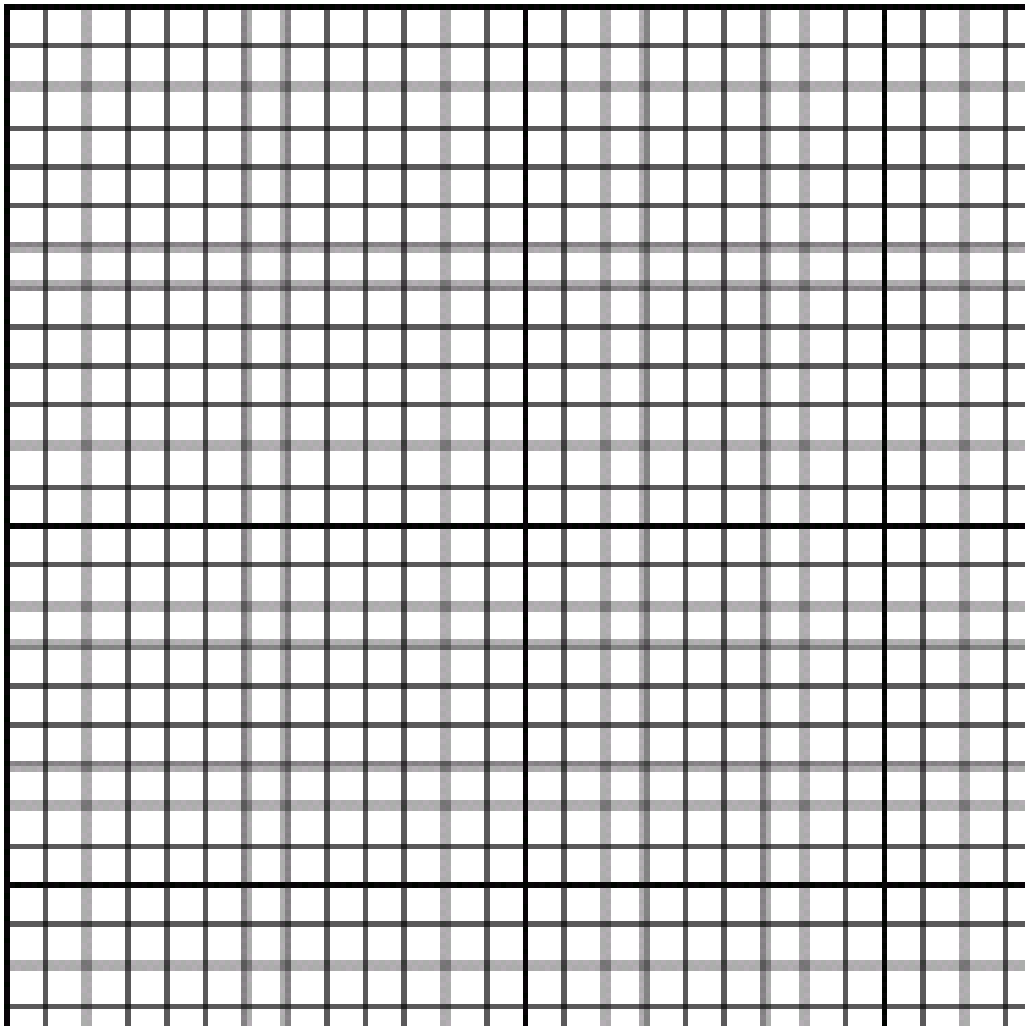

Raster, Original

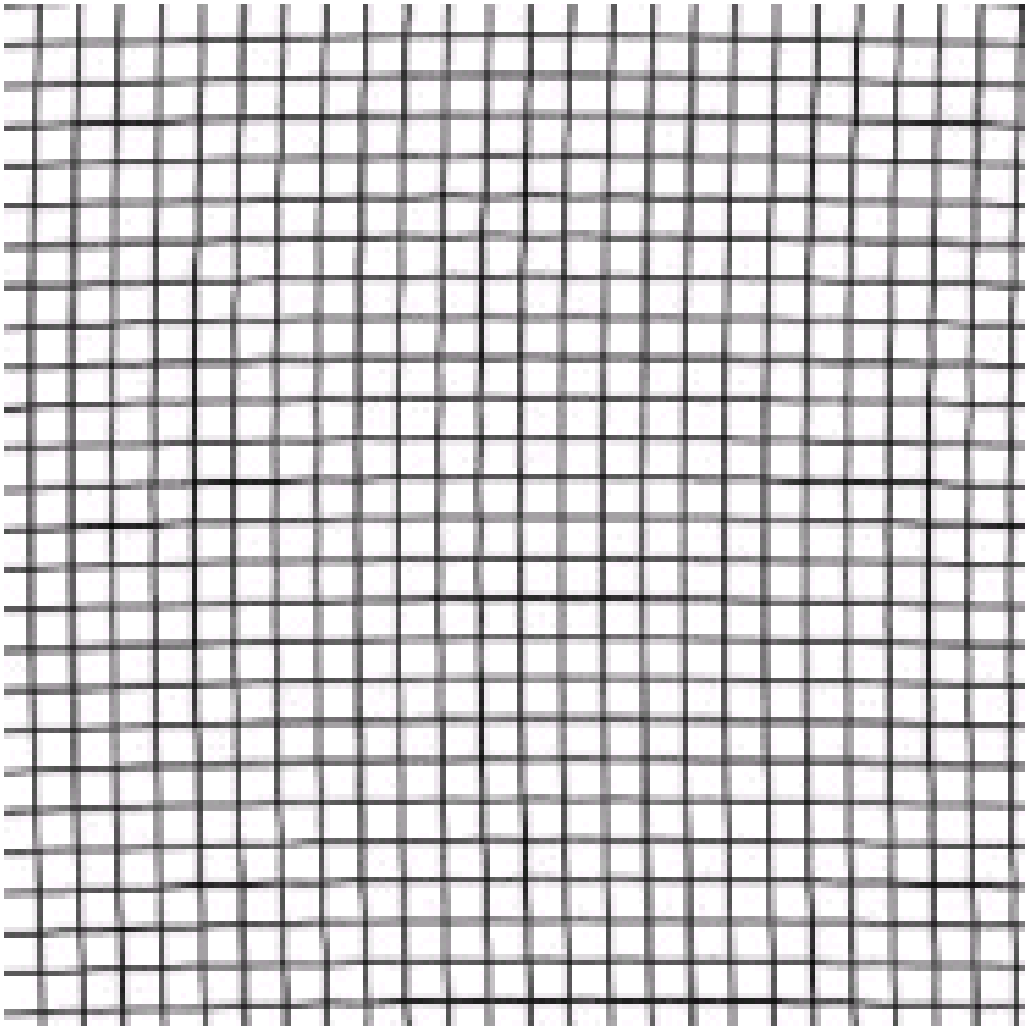

Raster, steganographisch verändert

Beispielimplementierung

- steghide von Stefan Hetzl
- Einbettung in Bilder (JPEG und BMP) und Audiodateien (WAV, AU)

```
1 steghide embed -cf   träger.jpeg -ef geheim.txt
2 steghide extract -sf träger.jpeg
```

Variation des TTL-Wertes von IP Paketen

- Time-to-Live: Zahl im Header von IP Paketen, die nach jedem passierten Rechner dekrementiert wird
- Verhindern von „Endlosrouting“ durch TTL (A schickt Paket an B, B zurück zu A)
- Übermittlung von Daten durch unterschiedliche TTL-Werte in IP Paketen

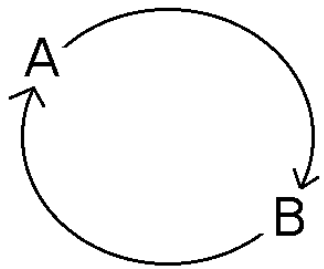

Beispiel: Variation des TTL-Wertes

Variation des TTL-Wertes nach einem (hier sehr einfachen) Algorithmus:

- Zuordnung:
  TTL des empfangenen Pakets → Buchstabe im Alphabet
  $1 \mapsto a$,
  $2 \mapsto b$,
  ...
- Beispiel-Route: Sender → Router → Empfänger:
  1. Sender schickt Paket mit TTL 13
  2. Router dekrementiert TTL auf 12
  3. Empfänger empfängt Paket mit TTL 12
  4. Interpretiert Paket als „L“

Beispiel: Variation des TTL-Wertes

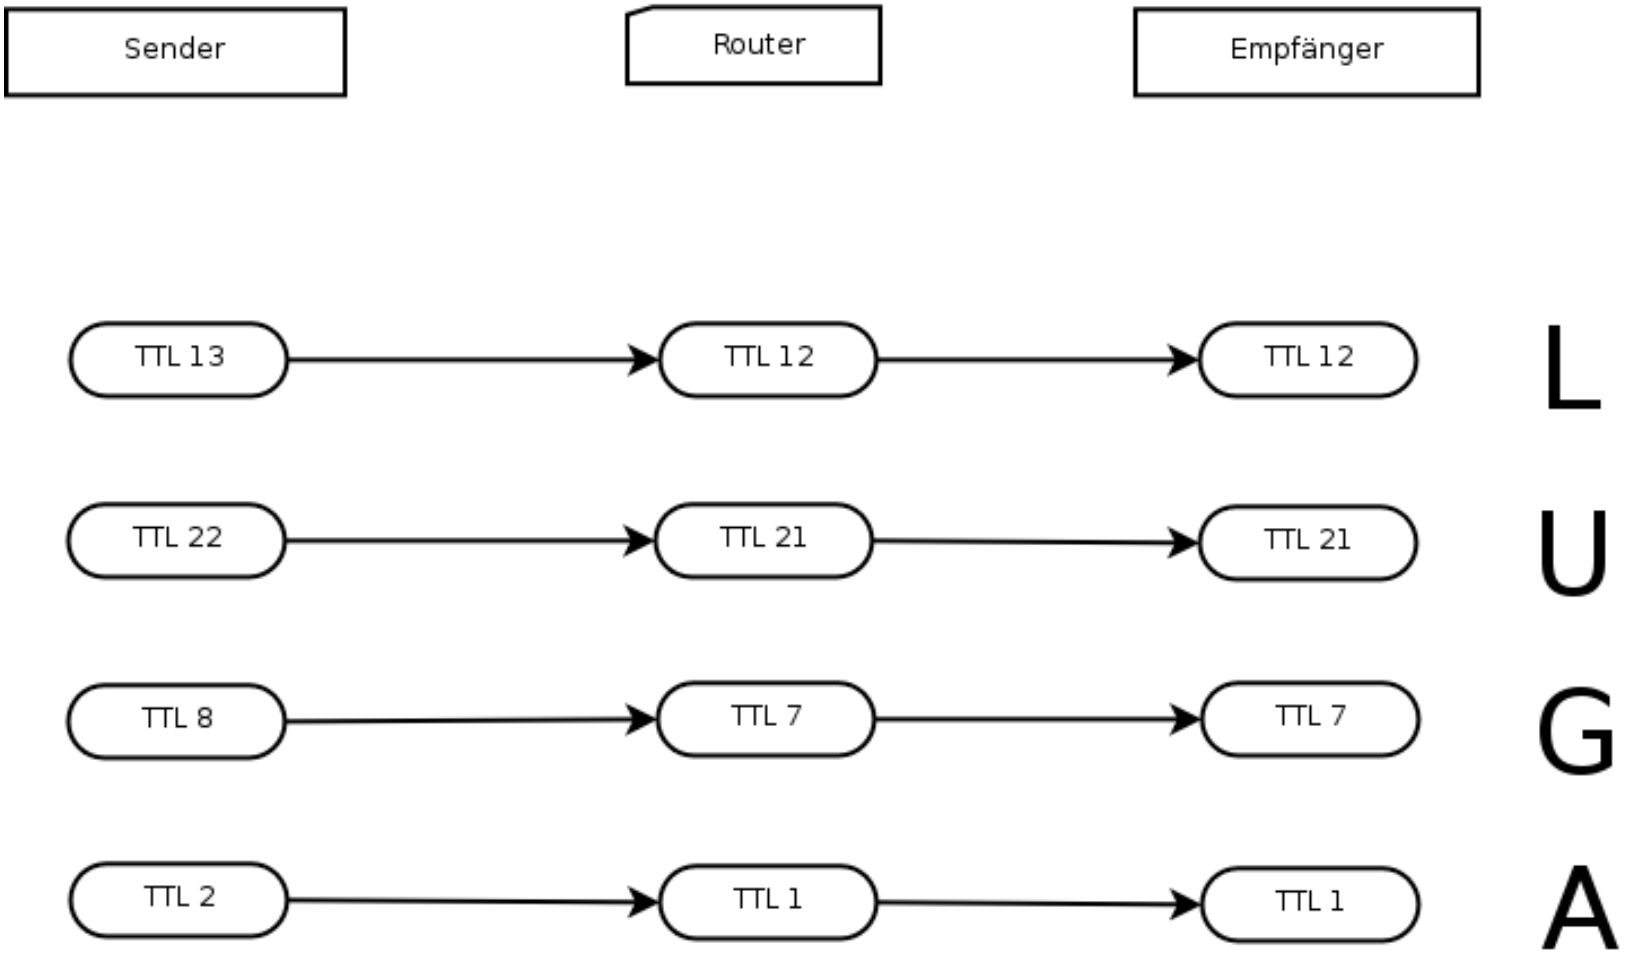

Domain Name Service (DNS)

$$\left.\begin{array}{l}1.\ \text{Nicht-rekursiver}\\ 2.\ \text{Rekursiver}\\ 3.\ \text{Nicht-rekursiver}\end{array}\right\}\ \text{Lookup auf nicht existente Domain} \rightarrow \begin{cases}\text{NOERROR} & := 0\\ \text{NXDOMAIN} & := 1\\ \text{NXDOMAIN} & := 1\end{cases}$$

- Setzen eines Bits:
  `$ dig @ns bit-addr +recursive`
- Abfragen eines Bits:
  `$ dig @ns bit-addr +norecursive` →
  NOERROR? → `0`
  NXDOMAIN? → `1`
- ...mit `bit-addr` beispielsweise `1234.pugs-rules.de` für das 1234. Bit

Beispielimplementierung

Live-Demo

Beispielimplementierung

- Beispielimplementierung dnsx von `http://xrl.us/lugadnsx`
- Benötigtes nicht-Standard-Perl-Modul: Net::DNS
- Installation über:

```
# apt-get install libnet-dns-perl
```
oder:
```
# perl -MCPAN -eshell
> install Net::DNS
```

Speichern im DNS

```
$ ./dnsx \
    --nameserver=Nameserveradresse \
    --domain=Unbenutzte Domain \
    --mode=store
```

(dnsx liest von der Standardeingabe.)

Holen aus dem DNS

```
$ ./dnsx \
    --nameserver=Nameserveradresse \
    --domain=Unbenutzte Domain \
    --mode=receive \
    --length=Länge der Daten
```

(dnsx schreibt auf die Standardeingabe.)

Anmerkungen zu dnsx

- Wahl einer unbenutzten Domain als `--domain` zwingend
- Keine „prinzipielle Korrektheit“ der Domain erforderlich;
  beispielsweise Möglichkeit von
  `--domain=weltklasse.9live`
- Unterdrücken der Debuggingmeldungen durch Umleitung der Standardfehlerausgabe

Tastaturverzögerung mit JitterBugs

- Verbergen von Information durch systematische Verzögerung von Tastenanschlägen durch ein externes Gerät zwischen Tastatur und Computer
- Mathematisches Prinzip:

  Δt: Zeitdauer zwischen zwei Anschlägen
  T: Zeitfenster, bspw. 20 ms

  Übertragung von 0?
  $\rightarrow$ Verzögerung so, dass Δt durch T teilbar

  Übertragung von 1?
  $\rightarrow$ Verzögerung so, dass $\Delta t + \frac{T}{2}$ durch T teilbar

Beispiel

- Zeitdauer zwischen Anschlägen des Benutzers:
  $42\,\text{ms},\quad 57\,\text{ms},\quad 19\,\text{ms},\quad 86\,\text{ms}$
- Zeitfenster: $T = 20\,\text{ms}$
- Zu übertragende Information: 1011_2
- Zeitdauer zwischen den Anschlägen nach künstlicher Verzögerung:
  $\underbrace{60\,\text{ms}}_{1},\quad \underbrace{70\,\text{ms}}_{0},\quad \underbrace{20\,\text{ms}}_{1},\quad \underbrace{100\,\text{ms}}_{1}$

Trotz verschiedenen Quellen von Rauschen. . .

. . . Detektierbarkeit solcher Verzögerungen übers Netzwerk! (!!)

Live-Demo

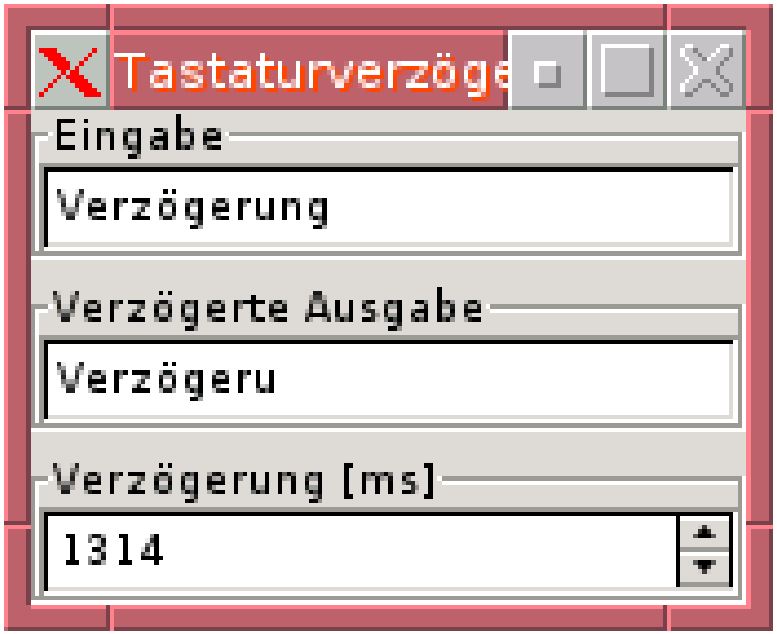
Tastaturverzöge
Eingabe
Verzögerung
Verzögerte Ausgabe
Verzögeru
Verzögerung [ms]
1314

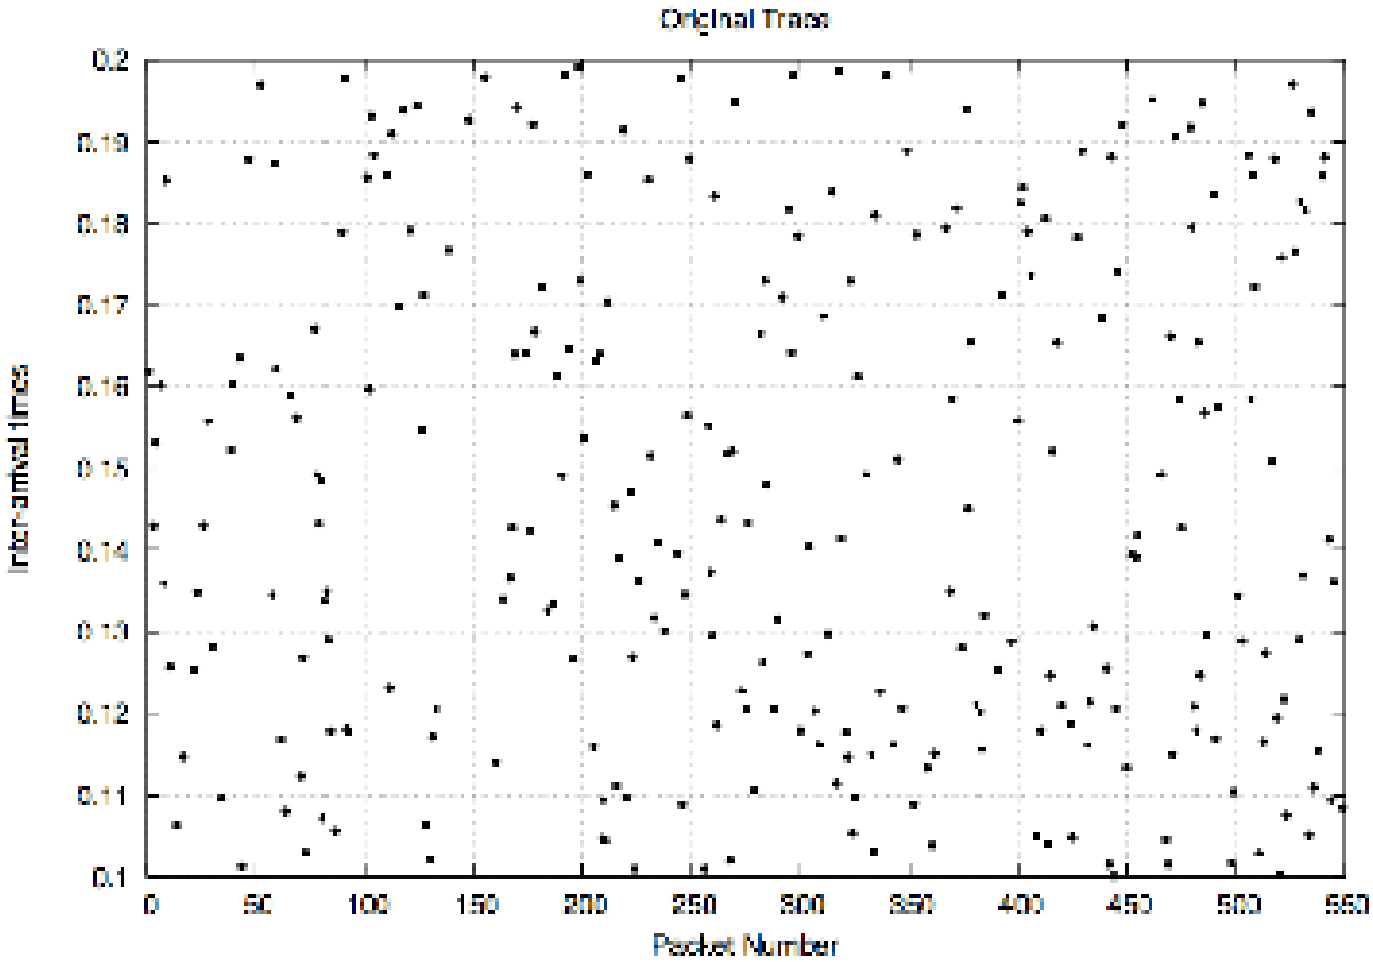

Ohne JitterBugs

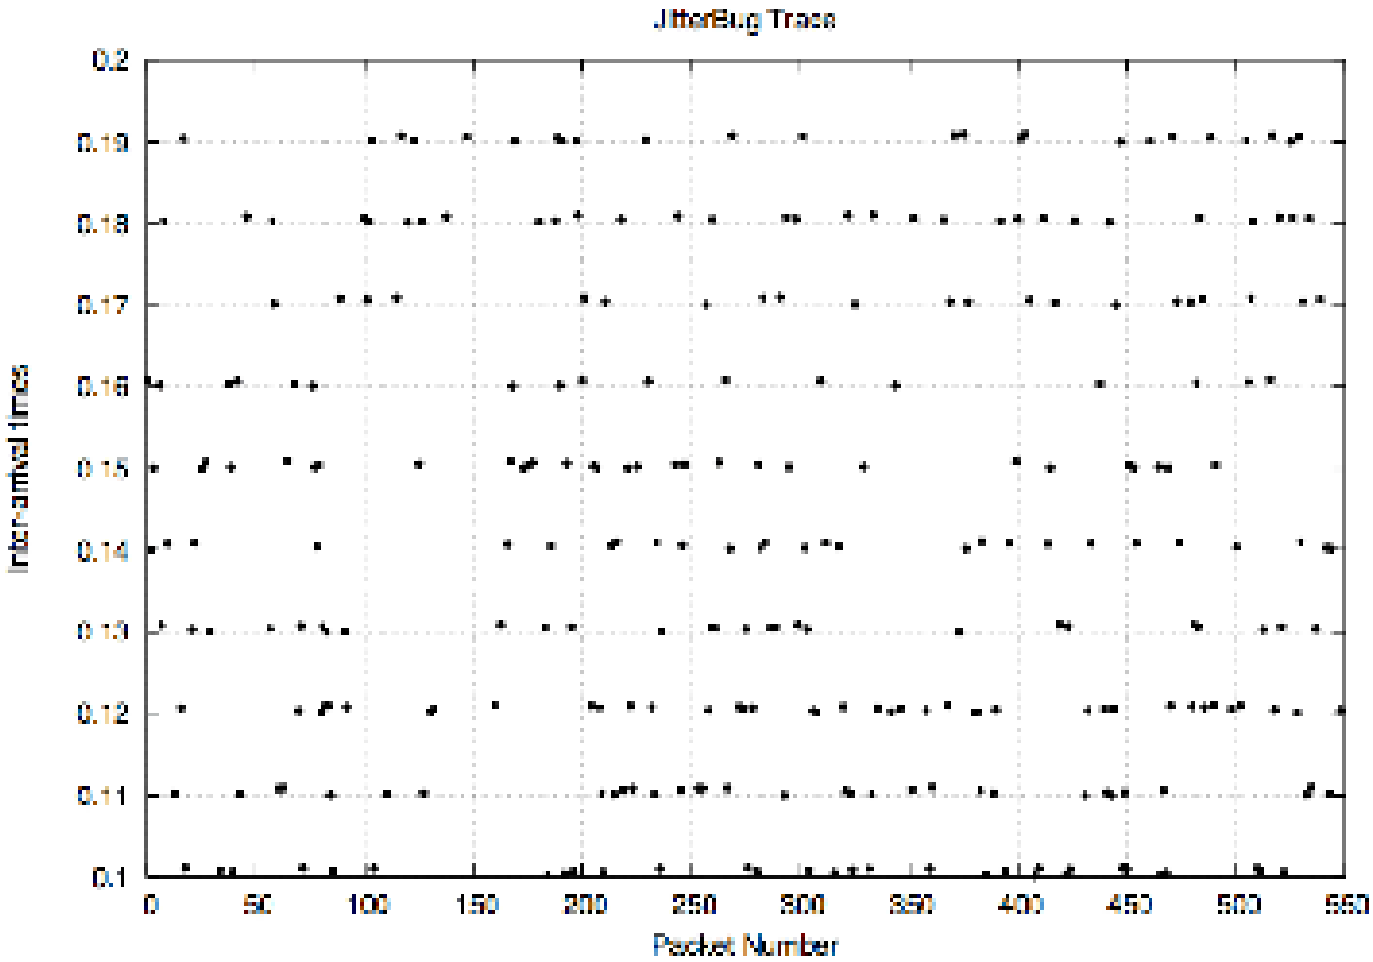

Mit JitterBugs

Fragen?

Literatur

- http://arxiv.org/pdf/math.HO/0404335
- http://m19s28.vlinux.de/iblech/klasse11/Sonstiges/1337/LUGA/DNS.pdf.pdf
- https://db.usenix.org/events/sec06/tech/shah/shah_html/index.html
- http://www.expmath.org/expmath/volumes/11/11.3/Calude361_370.pdf
- http://www.petitcolas.net/fabien/publications/ieee99-infohiding.pdf

Bildquellen

- http://perl.plover.com/yak/presentation/samples/present.gif
- https://db.usenix.org/events/sec06/tech/shah/shah_html/index.html
- http://www.alte-geschichte.uni-hd.de/grafik/tempel1.jpg
- http://www.htwm.de/~sstiller/kroatien/Postkarte%20Balaton%202.jpg
- http://www.meganandjack.com/mt/archives/signals4.jpg
- http://www.petitcolas.net/fabien/publications/ieee99-infohiding.pdf

Bonus-Slides

4 Algorithmische Informationstheorie (AIT)
- Algorithmische Information
- Vergleich zur Entropie

Algorithmische Informationstheorie (AIT)

- Problem am Entropiekonzept:
  Entropien von
  00001111 und
  01101000 gleich!
- Reihenfolge spielt beim Entropiekonzept keine Rolle!
- Lösung: Algorithmische Information –
  Länge des kürzesten Programms einer bestimmten Programmiersprache, die die jeweilige Zeichenkette ausgibt

$$H(x) := \min\{|p| \mid M(p) = x\};$$

$M(p)$: Ausgabe des Programms m

Vergleich zur Entropie

- Beachtung der Reihenfolge durch die algorithmische Information
- Bessere Erfassung des anschaulichen Konzepts *Ordnung*:

  00001111: 4 Nuller gefolgt von 4 Einsern
  01101000: Eine Null, zwei Einser, eine Null, eine Eins, drei Nuller
- Allerdings: Praktische Bestimmung von $H(x)$ mitunter schwierig, da Ausprobieren sehr vieler Programme notwendig
- *Weitreichende, hier nicht näher genannte Konsequenzen für die Mathematik!*
  Stichworte: G. Chaitin, CHAITINsche Konstante/Haltewahrscheinlichkeit Ω, ...