

# Auf dem Weg zu Website-Fingerprinting in der Praxis

Identifizierung von Webseiten mit dem  
multinomialen Naïve-Bayes-Klassifizierer

Dominik Herrmann

Lehrstuhl Management der Informationssicherheit  
Universität Regensburg

11.02.2008

# Überblick

## Website-Fingerprinting

Idee und Zielsetzung

## Verbessertes Website-Fingerprinting-Verfahren

Multinomialer Naive-Bayes-Klassifizierer

Transformation der Häufigkeitsvektoren

## Evaluation und Analyse

Versuchsaufbau

Evaluation mit OpenSSH

Schutz durch JonDonym und Tor

## Forschungsfragen

# Ziel: Identifizierung verschlüsselt übertragener Webseiten

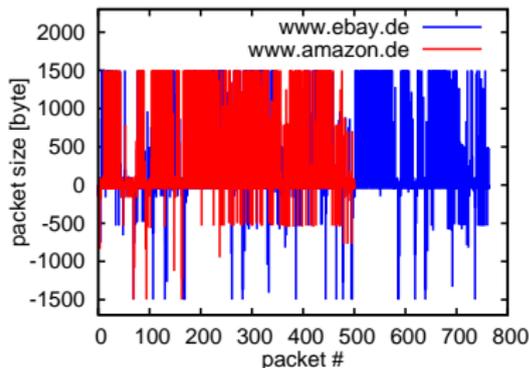
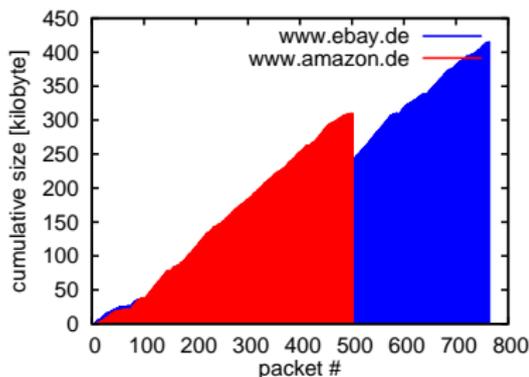
Wie sicher sind datenschutzfreundliche Übertragungsverfahren?

- ▶ Weitverbreitete Annahmen:
  - ▶ Abruf von Webseiten über verschlüsselnde Tunnel (z. B. OpenSSH, VPNs, JonDonym, Tor) gewährleistet Vertraulichkeit
  - ▶ Angreifermodell solcher Dienste: Schutz der Inhalte (auch URLs!) vor *lokalem Angreifer*
- ▶ Mit Website-Fingerprinting kann auch ein lokaler Angreifer die abgerufenen URLs ermitteln
- ▶ Verschiedene Motive denkbar:
  - ▶ User-Profiling: *Welche Webseiten wurden abgerufen?*
  - ▶ Strafverfolgung: *Wurde Webseite X abgerufen?*

# Charakteristischer Traffic beim Abruf einer Webseite

Website-Fingerprinting basiert auf der Erkennung typischer Muster im Datenverkehr

- ▶ IP-Paketgrößen als robustes Merkmal
- ▶ Pakete in Senderichtung (Client → Server): negative Größe
- ▶ Netzwerk-Traces für [www.amazon.de](http://www.amazon.de) und [www.ebay.de](http://www.ebay.de):



# Idee: Anwendung von Data-Mining-Techniken

Data-Mining-Know-How und Verfahren für Website-Fingerprinting nutzen

- ▶ Aber: Korrelation von Netzwerk-Traces nicht trivial  
→ Vielversprechendes Anwendungsfeld für Data-Mining
  
- ▶ Website-Fingerprinting als Klassifizierungsproblem
  - ▶ Klassen: Webseiten (URLs)
  - ▶ Instanzen: *tcpdump*-Netzwerk-Traces
  - ▶ Attribute: Häufigkeiten der IP-Paketgrößen
  
- ▶ Im Text-Mining verbreitet:  
Multinomialer Naïve-Bayes Klassifizierer

# Basis für Naïve-Bayes: Termhäufigkeitsvektoren

Netzwerk-Traces lassen sich als (Term-)Häufigkeitsvektoren darstellen

1. Ermittlung des Vokabulars  $V$  aller Trainingsinstanzen
2. Erzeugung der Häufigkeitsvektoren  $\mathbf{f}$

$$d_1 = \text{"-152 1500 - 52 1050 1500 - 80"}$$

$$d_2 = \text{"-148 476 1500 - 80"}$$

$$V = \{-152, 1500, -52, 1050, -80, -148, 476\}$$

$$\mathbf{f} = \langle f_{-152}, f_{1500}, f_{-52}, f_{1050}, f_{-80}, f_{-148}, f_{476} \rangle$$

$$\mathbf{f}_{d_1} = \langle 1, 2, 1, 1, 1, 0, 0 \rangle$$

$$\mathbf{f}_{d_2} = \langle 0, 1, 0, 0, 1, 1, 1 \rangle$$

# Multinomialer Naïve-Bayes-Klassifizierer

Trotz naiver Annahmen (positional/conditional independence) gute Erkennungsraten

$$d \text{ gehört zu } c: P(c|d) = \frac{P(c)P(d|c)}{P(d)} \quad \text{hier: } P(c|d) \propto P(d|c)$$

Wie gut wird  $c$  durch  $d$  repräsentiert? → Wie wahrscheinlich ist es,  $d$ 's Terme in Dokumenten, die zur Klasse  $c$  gehören, anzutreffen?

$$P(d|c) = P(\mathbf{f}|c) = C_{multi} \cdot \prod_{t \in V} P(t|c)^{f_{t,d}}$$

$$\hat{P}(t|c) = \frac{f_{t,c}}{\sum_{t' \in V} f_{t',c}}$$

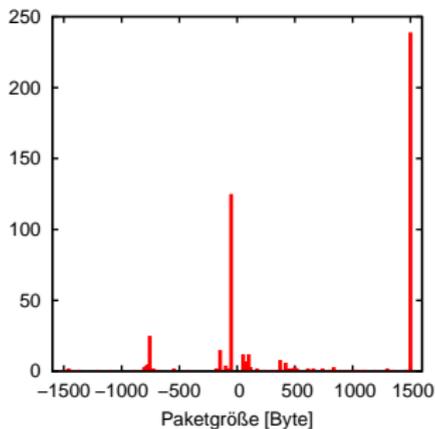
(nach [Manning])

# Transformation der Häufigkeitsvektoren

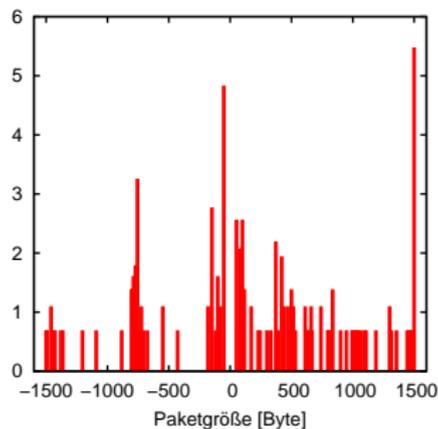
Durch Transformation der Häufigkeitsvektoren lässt sich die Erkennungsleistung steigern

▶ TF-Transformation:  $f_{t,d}^* = \log(1 + f_{t,d})$  nach [Manning]

▶ Normalisierung:  $f_{t,d}^{\text{norm}} = \frac{f_{t,d}^*}{\| \langle f_{t_1,d}^*, \dots, f_{t_n,d}^* \rangle \|} = \frac{f_{t,d}^*}{\sqrt{\sum_{t' \in V} (f_{t',d}^*)^2}}$



→



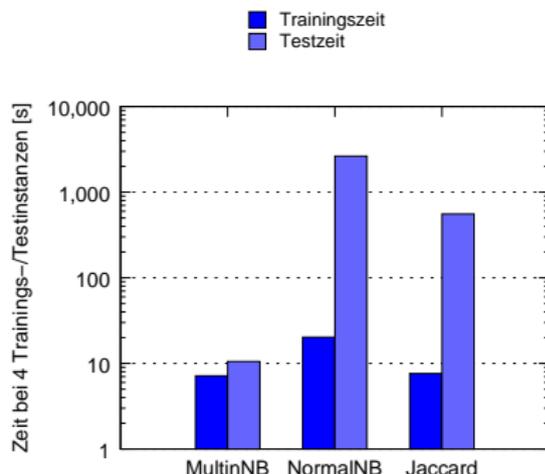
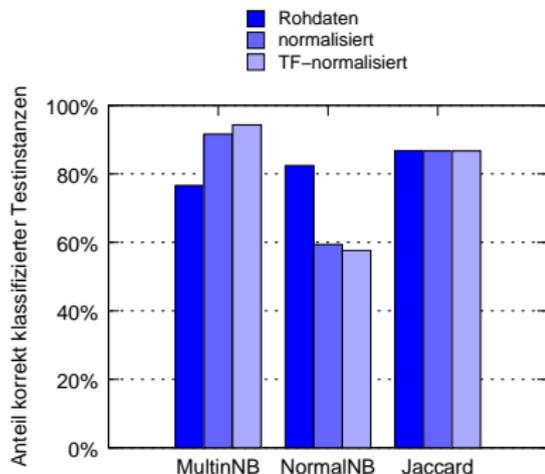
# Versuchsaufbau für Evaluation

Versuchsaufbau vergleichbar mit bisherigen Veröffentlichungen

- ▶ 775 populäre Webseiten, Abruf mit Firefox [JSSh]
  - ▶ Aufzeichnung der IP-Paket-Header mit *tcpdump*
  - ▶ 25 Stichproben pro Versuch, jeweils 10 Testinstanzen
  - ▶ Getestete Systeme: OpenSSH, Tor, JonDonym
- 
- ▶ Benchmark: 70 % korrekt klassifizierte Instanzen bei OpenSSH [Liberatore 2006]

# Vergleich mit anderen Website-Fingerprinting-Verfahren

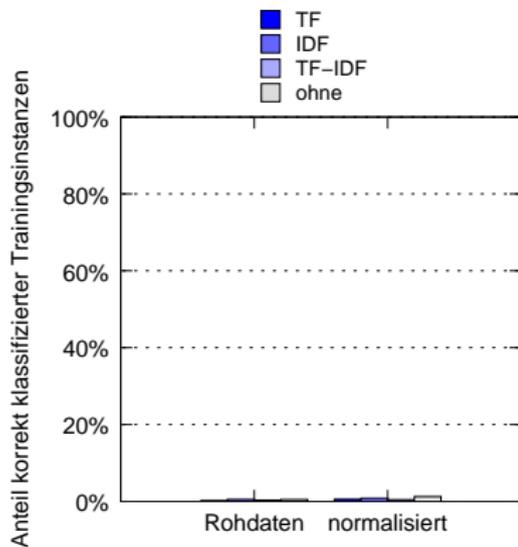
Multinomiale Naïve-Bayes-Klassifizierer ist schneller und besser als etablierte Verfahren



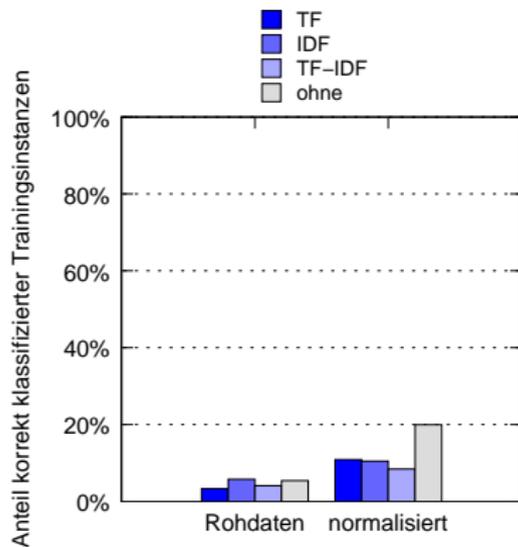
- **Multinomiale-Naïve-Bayes-Klassifizierer:**  
**94 % Erkennungsrate bei 4 Trainingsinstanzen**

# Evaluierung mit JonDonym und Tor

Heutige Anonymisierer bieten bereits guten Schutz gegen Website-Fingerprinting



Tor



JonDonym

# Offene Forschungsfragen

## Herausforderungen für Verwendung von Website-Fingerprinting in der Praxis

**Effiziente Gegenmaßnahmen** Padding ist wirksam, aber teuer.

Alternativen denkbar: z. B. Burst-Proxy

**Gezielte Erleichterung** Kann Betreiber einer Webseite

Identifizierung mutwillig erleichtern?

**Überbrückung von Anonymisierern** Verteilter Angriff; lassen sich

Anonymisierer damit überbrücken?

**Einfluss von Caching** Funktioniert Fingerprinting bei aktiviertem

Browser-Cache?

**Einsatz in Praxis** Unterstellung von Denkpausen ist idealistisch; bei

Hintergrundtraffic überhaupt durchführbar?

**Bedeutung der False Positive Rate** Bislang Fokus auf True

Positives; False Positives ebenso relevant!

**Robustheit** Einfluss von Browser, Plugins, ISP?

# Zusammenfassung

- ▶ Text-Mining-Verfahren auf Netzwerk-Traces anwendbar
- ▶ Vorgestelltes Verfahren hat hohe Erkennungsleistung bei OpenSSH
- ▶ Existierende Anonymisierer erschweren Fingerprinting

## Referenzen



M. Liberatore and B. N. Levine: Inferring the source of encrypted HTTP connections. In CCS '06: Proc. of the 13th ACM conference on Computer and communications security, p. 255-263, New York, 2006.



JSSh – TCP/IP JS Shell Server for Mozilla (<http://crozzilla.com/jssh>)



C. D. Manning, P. Raghavan, and H. Schütze: Introduction to Information Retrieval (draft; Nov. 17, 2007). Cambridge University Press, 2007 (<http://nlp.stanford.edu/IR-book/pdf/irbookprint.pdf>).