



## SEODisc: Ansatz zur Erkennung von SEO-Attacken

---

**Matthias Meyer**

21. März 2011

TU Dortmund, G Data



---

# Inhaltsverzeichnis

- 1 Einleitung**
  - Was ist SEO?
  - SEO aus Angreifersicht
  - SEO Techniken
- 2 Verfolgter Lösungsansatz**
  - Lösungsansatz
- 3 Ergebnis**



---

# Was ist SEO?

- SEO = Search Engine Optimization
- Ziel: Verbesserung der Positionierung einer Webseite in den Suchergebnissen
- Meist auf Google optimiert
- Unterscheidung in *White-Hat-SEO* und *Black-Hat-SEO*



## Einleitung

# Wieso Interessant für Angreifer

- Suchanfragen Dez. 2009: <sup>1</sup>
  - Weltweit: ca. 131 Milliarden Suchanfragen
  - Google: ca. 87 Milliarden Suchanfragen ( ca. 66 %) bzw. ca. 2.8 Milliarden Suchanfragen täglich
- Positionierung in den Top 20 Suchergebnissen  
⇒ viele potentielle Opfer.
- Funktionierendes Cloaking ⇒ keine Erkennung durch Crawler
- Infektionsvektor über z.B. Drive-By-Downloads schwer durch zentrale Mittel zu filtern.
- Finanzieller Aspekt (Werbebanner) durch hohen Traffic.

---

<sup>1</sup>Quelle: ComScore - [www.comscore.com](http://www.comscore.com) - Pressemitteilung 22.01.2010



# White-Hat-SEO

- On-Site
  - Meta Tags (Header, Description)
  - Suchmaschinenfreundliche URLs
  - Keywords in Überschriften verwenden
  - Vereinfachte Navigation
  - Bilder: Verwenden von ALT und Description Tags
- Off-Site
  - Link-Building





# Black-Hat-SEO

- Black-Hat-SEO = White-Hat-SEO + ...
  - Content Spam
  - Keyword stuffing
  - Cloaking
    - Textfarbe
    - NoScript
    - CSS / JavaScript
    - Auswertung User-Agent
    - Auswertung Referrer
  - Link-Building
  - ...





## Möglicher Angriff

- 1 Erstellen einer Webseite zum Thema  $T$  unter URL  $L_D$
- 2 Aufbau eines SEO Netzes zum Thema  $T$ 
  - Unbemerkte Übernahme existierender Webseiten  $L_1, L_2, \dots, L_n$  zum Thema  $T$
  - Einfügen von Links zu allen  $L_i$  (versteckt vor menschlichen Besuchern)
  - Einfügen versteckter Links zu  $L_D$
- 3 Verstecken der Manipulation durch Cloaking Techniken
  - Filtern der Seiteninhalte nach Referrer
  - Filtern der Seiteninhalte nach User Agent



Verfolgter Lösungsansatz

---

# Der Lösungsansatz

## 3 verschiedene Teilprobleme

- Finden potentiell verseuchter Webseiten (Kandidatenfindung)
- Finden von versteckten Inhalten
- Erkennen von SEO-Netzen





Verfolgter Lösungsansatz

# Der Lösungsansatz

## Problem

Finden potentiell verseuchter Webseiten

## Annahme

- Black-Hat SEOs verwenden Schlagworte zu aktuellen Themen (z.B. Erdbeben Japan)
- Da Schlagworte aktuell vermehrt gesucht  $\Rightarrow$  steiler Anstieg in den Google Trends
- Verbesserung des Rankings als Folge der SEO sorgt für Position in den Top 25 Suchergebnissen.

...



Verfolgter Lösungsansatz

# Der Lösungsansatz

## Problem

Finden potentiell verseuchter Webseiten

## Lösung

- Abfrage der Top 20 Keywords der Google Trends und Google Hot Topics (stündlich)
- Für gefundene Keywords  $\Rightarrow$  Googleuche und speichere Top 25 Ergebnisse
- Gefundene URLs: Abruf der Webseite mit verschiedenen emulierten UserAgents

...



Verfolgter Lösungsansatz

# Der Lösungsansatz

## Problem

Finden potentiell verseuchter Webseiten

## Vorgehen

- $\sum$  10 Abrufe einer Webseite
  - 5 Abrufe ohne Referrer Header gesetzt
  - 5 Abrufe mit Google Suche als Referrer
- Abruf jeweils mit emuliertem User Agent
  - Google Crawler
  - Firefox (3er Serie)
  - Internet Explorer (6er Serie)
  - 2x Neutraler User Agent (GTFetch)



Verfolgter Lösungsansatz

# Der Lösungsansatz

## Problem

Finden von versteckten Inhalten

## Annahme

- Links auf SEO-Netz Mitglieder werden durch nicht triviale cloaking Maßnahmen versteckt
- Das Augenmerk liegt im Verstecken vor menschlichen Benutzern



# Der Lösungsansatz

## Aufgabe

Differenzanalyse einer Webseite - Erkennen von versteckten Links

## Vorgehen

- Suche Linkentsprechungen
  - $\forall$  Links  $L_i \in W_{Google}$  suche Entsprechung in  $W_{FF}$
  - $\forall$  Links  $L_i \in W_{Google}$  suche Entsprechung in  $W_{IE}$
  - $\forall$  Links  $L_i \in W_{Google}$  suche Entsprechung in  $W_{Neutral}$
- Suche Links in "dynamischem Content"
  - $\forall$  Links  $L_i \in W_{Neutral_1}$  suche Entsprechung in  $W_{Neutral_2}$
- Vergleiche Anzahl Links zwischen Referrer und None-Referrer Variante (Referrer-Analyse)



Verfolgter Lösungsansatz

# Der Lösungsansatz

## Aufgabe

Differenzanalyse einer Webseite -  
Finden von versteckten Texten

## Vorgehen

- Ermittlere relative Schlagwortdichte pro Webseitenversion
  - Berechne Schlagwortdichte von  $W_{Google}$ ,  $W_{FF}$ ,  $W_{IE}$ ,  $W_{Neutral_1}$  sowie  $W_{Neutral_2}$
  - Vergleich der Schlagwortdichte zwischen Versionen der Webseite
- Suche Inhalte in "dynamischem Content"
  - Vergleich Schlagwortdichte  $W_{Neutral_1}$  vs.  $W_{Neutral_2}$



Verfolgter Lösungsansatz

# Der Lösungsansatz

## Problem

Erkennen von SEO-Netzen

## Annahme

- Black-Hat SEOs besitzen eigene versteckte Netzstrukturen zum pushen von infizierten Webseiten
- Diese Netzstruktur ist über versteckte Links miteinander vernetzt
- Es existieren Zyklen in dieser Netzstruktur aufgrund der möglichst vollständigen Vernetzung

...



Verfolgter Lösungsansatz

# Der Lösungsansatz

## Problem

Erkennen von SEO-Netzen

## Lösung

- Aufbau eines Graphen mit gefundenen Links aus der Differenzanalyse
  - Knoten = URLs
  - Kanten = Links
- Suche im Graphen nach Zyklen und Zusammenhangskomponenten
- Jede Zusammenhangskomponente bildet ein SEO-Netz
- In jedem SEO-Netz suche Knoten mit hoher Zahl eingehender Kanten







---

## Gewonnene Erkenntnisse

- Experiment durchgeführt:
  - 2 Zeiträume: 23.09.10 - 04.11.10 und 02.01.11 - 15.01.11
  - Insgesamt analysierte Webseiten: 660.749
  - 43 potentielle SEO-Netze gefunden worden
- Keine eindeutige Erkennung von schädlichen Webseiten in SEO-Netzen



Ergebnis

---

# Aufmerksamkeit ...

# Danke für Ihre Aufmerksamkeit

Kontakt: [Matthias.Meyer@tu-dortmund.de](mailto:Matthias.Meyer@tu-dortmund.de) /  
[Matthias.Meyer@gdata.de](mailto:Matthias.Meyer@gdata.de)  
Infos: [www.seodisc.de](http://www.seodisc.de) (coming soon)