

Follow Along

Die Folien finden Sie unter:

<https://kolloquium.teismar.de>



Bachelorarbeit Kolloquium

Detection and Classification of Phishing Sites by Analyzing Common Patterns

Leibniz-Fachhochschule Hannover
In Kooperation mit Deutsche Telekom Security GmbH

Tim Julian Eismar | Matrikelnummer: 45768

21. Juli 2025

Let's go phishing →


Gliederung

- 1** Motivation
- 2** Methodischer Überblick
- 3** Praktische Umsetzung
- 4** Ergebnisse
- 5** Fazit und Ausblick

Das Phishing-Problem

Aktuelle Bedrohungslage

- Zunehmende Anzahl und Raffinesse von Phishing-Angriffen
- Phishing-Kits ermöglichen einfache Erstellung betrügerischer Websites
- Schwierigkeit bei der Zuordnung neuer Seiten zu bekannten Kits




Zielsetzung

Was wollen wir erreichen?

- Automatische Klassifizierung neuer Phishing-Sites
- Actionable Intelligence
- Schnelle Reaktion auf neue Bedrohungen

Die zentrale Herausforderung



Forschungsfragen

1. Merkmalsdefinition

Welche Merkmale können zur Identifizierung von Phishing-Kits verwendet werden?

2. Merkmalsextraktion

Wie können diese Merkmale automatisch extrahiert werden?

3. Matching-Verfahren

Wie können extrahierte Merkmale zur Zuordnung verwendet werden?

Methodischer Überblick

1. Merkmalsdefinition

- Analyse bestehender Phishing-Kits
- Identifikation gemeinsamer Charakteristika

2. Merkmalsextraktion

- Automatisiertes Aufsetzen von Phishing-Websites
- Feature-Extraktion mittels Web-Scraping


3. Matching

- Preprocessing der Merkmale
- Anwendung von Clustering-Algorithmen (DBSCAN)

4. Evaluation

- Manuelle Validierung der Ergebnisse

Systemüberblick



DBSCAN - Warum diese Wahl?

Vorteile für Website-Analyse

- Beliebige Cluster-Formen (nicht nur kreisförmig)
- Robust gegen Rauschen und Ausreißer
- Automatische Cluster-Anzahl
- Keine Vorab-Annahmen über Cluster-Form

Besonders wichtig für Phishing-Sites:

- Erkennung unterschiedlicher Kit-Strukturen
- Automatische Outlier-Erkennung
- Keine Vorab-Cluster-Anzahl erforderlich


Datensammlung - Quellen

Woher kommen die Daten?

- VirusTotal (Premium API)
- UrlScan (Premium Zugang)
- Phishing-Repositories
- Directory Listings

Fokus auf PHP/HTML

- 3.900 Phishing-Samples analysiert
- 3.481 enthalten PHP oder HTML
- 462 Samples für Experimente verwendet



Feature-Extraktion - HTML

Strukturelle Merkmale

- **Link-Anzahl** (link_count)
- **Formular-Felder** (form_count)
- **Script-Tags** (script_count)
- **Passwort-Eingaben** (password_input_count)

Inhaltliche Merkmale

- **Sichtbare Textlänge** (visible_text_length)
- **Keyword-Häufigkeiten** (login, password, verify)
- Meta-Tags und Kommentare

Feature-Extraktion - HTTP

Response-Charakteristika

- Status-Codes
- Response-Größe
- Antwortzeit
- Content-Type Headers

Verhalten

- Cookies und Sessions
- Redirect-Verhalten
- Error-Handling

Feature-Extraktion - Scoring

Bewertungsmethoden

Kategoriale Entropie:

$$S = - \sum_i p_i \log_2(p_i)$$

Numerische Varianz:

Streuung der Merkmalswerte

Gewichtete Gesamtbewertung:


Kombination beider Maße

Datenvorverarbeitung

- One-Hot-Encoding für kategoriale Features
- Standardisierung numerischer Features
- PCA für Dimensionsreduktion

Let the machine learn

- 50 Pfade /index.php , /login.php , etc.
- Lange wartezeit
- uuuuund...




Experimentelle Ergebnisse - Pfadanzahl

Iterative Analyse

- Evaluation für 1-50 Pfade
- Silhouette-Score als Qualitätsmaß

Beobachtungen

- **1 Pfad:** Unzureichende Information
- **2 Pfade:** Optimale Balance
- **>2 Pfade:** Curse of Dimensionality



Clustering-Ergebnisse (2 Pfade)

Cluster-Verteilung

Cluster	Anzahl Samples	Charakteristikum
-1	4	Rauschen
0	156	Fehlende Index-Dateien
1	259	Malformierte Sites
2-6	4-19	Logische Gruppierung

Beobachtung

Kleinere Cluster (2-6) zeigen **hohe Kohärenz** und sinnvolle Gruppierung


Erfolgreiche Cluster-Analyse

Cluster 6: Telekom Login

- 5 identische Phishing-Sites
- Alle imitieren Telekom Login-Seite
- Visuell identische Darstellung
- Hohe Cluster-Kohärenz

Validierung bestätigt:

- Gemeinsame HTML-Struktur
- Identische Styling-Elemente
- Gleiche Formular-Felder



Analyse der großen Cluster

Cluster 0: Strukturelle Anomalien

- Websites ohne Standard-Index-Dateien
- Fehlende `index.html` oder `index.php`
- Content in Subdirectories
- **Evasion-Strategie**

Cluster 1: Anti-Bot Mechanismen

- Malformierte oder fehlerhafte Sites
- CAPTCHA und Bot-Protection
- **Defensive Mechanisms**

Bewertung - Erfolge

Was funktioniert gut:

- Automatische Feature-Extraktion funktioniert
- DBSCAN identifiziert sinnvolle Cluster
- Hohe Kohärenz in kleineren Clustern
- Strukturelle Anomalien erkannt
- Evasion-Techniken identifiziert

Das System identifiziert sowohl strukturelle
Ähnlichkeiten als auch Evasion-Techniken

Bewertung - Herausforderungen

Verbesserungsbedarf:

-  Große Cluster schwer interpretierbar
-  Limitierte Datenmenge (462 Samples)
-  PCA erschwert Feature-Interpretation
-  Manuelle Validierung erforderlich

Aber dennoch:

Grundlegende Machbarkeit **erfolgreich demonstriert**

Antworten auf Forschungsfragen

1. Identifikation von Merkmalen

- **HTML-Struktur** (Links, Forms, Scripts)
- **HTTP-Verhalten** (Status, Response-Size)
- **Dateihierarchie** und Pfad-Struktur

3. Matching-Verfahren

- **DBSCAN-basierte Clustering**
- **PCA** für Dimensionsreduktion
- **Silhouette-Score** Optimierung

2. Automatische Extraktion

- Docker-basiertes Aufsetzen von Phishing-Sites
- Web-Scraping Pipeline
- Strukturierte Feature-Extraktion

Fazit - Hauptergebnisse

Was haben wir erreicht?

- **Funktionsfähiges System** zur Phishing-Kit-Analyse
- **Strukturelle Muster** erfolgreich identifiziert
- **Automatisierte Pipeline** entwickelt
- **Validierung** durch manuelle Inspektion

Beitrag zur Cybersicherheit

Grundlage für **automatisierte Threat Intelligence**

Ausblick - Methodische Verbesserungen

Nächste Schritte

- Erweiterte Feature-Sets
- Verhaltensbasierte Merkmale
- Supervised Learning Integration
- Realzeit-Erkennung

Technische Erweiterungen

- Größere Datensätze (Tausende von Samples)
- Verbesserte Visualisierung
- Performance-Optimierung

Ausblick - Praktische Anwendung

Deployment Möglichkeiten

- **Integration in SOC-Systeme**
- **Kooperation mit Strafverfolgung**
- **Continuous Monitoring**
- **Threat Intelligence Feeds**

Forschungsrichtungen

- **Evasion-Techniken**
- **Multi-Language Support**
- **Cross-Platform Analysis**



Vielen Dank für Ihre Aufmerksamkeit!

Tim Julian Eismar

tim.eismar@telekom.de

*Leibniz-Fachhochschule Hannover
Deutsche Telekom Security GmbH*

Quellen

Dokumente & Recherche

- Meiner Bachelorarbeit zu entnehmen

Bilder & Medien

- [Unsplash](#)
- [Imgflip Meme Generator](#)
- [Google Imagen 4](#)
- [Medium](#)
- [Smartsoc Solutions](#)




Fragen?



Backup Folien

DBSCAN - Funktionsweise




Anhang: DBSCAN Parameterwahl (ϵ)

Bestimmung des Epsilon-Wertes (ϵ)

- Berechnung:** Für jeden Datenpunkt wird der Abstand zum k-nächsten Nachbarn berechnet (hier $k=\text{MinPts}$).
- Sortierung:** Die Abstände werden aufsteigend sortiert und aufgetragen.
- "Ellenbogen"-Kriterium:** Der optimale ϵ -Wert befindet sich am "Ellenbogen" (Knie) der Kurve. Dieser Punkt markiert den Übergang zwischen dichten Clustern (flacher Anstieg) und Rauschen (steiler Anstieg).


K-Distanz-Graph (Beispiel)



Curse of Dimensionality

Wenn Daten zu viele Merkmale (Dimensionen) haben, wird es schwierig:


- **Algorithmen werden ineffizient:** Berechnungen dauern länger und werden unzuverlässiger.
- **Abstände verlieren an Aussagekraft:** Die Ähnlichkeit zwischen Datenpunkten wird unklar.
- **Visualisierung ist unmöglich:** Wir können Daten in mehr als drei Dimensionen nicht darstellen.



PCA & 3D-Visualisierung

Principal Component Analysis (PCA)

- **Vorgehen:** PCA transformiert die ursprünglichen, korrelierten Merkmale in einen neuen Satz von unkorrelierten Merkmalen, die Hauptkomponenten. Die ersten wenigen Komponenten enthalten den Großteil der Information.
- **Wie:** PCA berechnet die Eigenvektoren und Eigenwerte der Kovarianzmatrix der Merkmale und wählt die Komponenten mit den höchsten Eigenwerten aus.



Ethische Überlegungen

- **Umgang mit Daten:** Die analysierten Phishing-Kits können potenziell personenbezogene Daten (PII) von Opfern enthalten (z.B. in Log-Dateien). Die Analyse erfolgte auf von Außen unzugänglichen, anonymisierten Servern um die Exposition von PII zu vermeiden.
- **Keine aktive Interaktion:** Das System interagiert passiv mit den gehosteten Seiten und führt keine Aktionen aus, die Daten an die Phishing-Akteure senden könnten (z.B. Ausfüllen von Formularen).
- **Zweckbindung:** Die Analyse dient ausschließlich dem Zweck der Forschung und der Verbesserung von Verteidigungsmechanismen.



Methodische Limitationen

- **Datensatzgröße:** Die Analyse basiert auf 462 Kits. Obwohl die Ergebnisse vielversprechend sind, ist eine Validierung auf einem größeren Datensatz für eine Verallgemeinerung notwendig.
- **Fokus auf PHP/HTML:** Die aktuelle Methode ist auf PHP- und HTML-basierte Kits ausgerichtet. Moderne Phishing-Seiten, die stark auf JavaScript-Frameworks setzen, erfordern möglicherweise erweiterte Features.
- **Manuelle Validierung:** Die finale Bewertung der Cluster-Qualität erforderte eine aufwändige manuelle Inspektion der Ergebnisse.

