

偽ショッピングサイト

自動検出システムの開発と今後の研究

An automatic detection system for fake shopping sites and future research

堺 啓介・システム分科会・情報セキュリティ大学院大学

Abstract - The proliferation of fake shopping websites is on the rise, however law enforcement agencies, such as the police, have not been able to implement comprehensive solutions. Therefore, there is a need for efficient and early detection methods. In this research, we created an automated detection system for fake shopping websites using machine learning, starting with a list of newly registered domains. We were able to achieve early detection of fake shopping websites and increase the efficiency of detection efforts.

研究背景

偽ショッピングサイトは増加傾向で、昨今のニュースでもシーズンに応じた注意喚起がなされるなど、その脅威は猛威を奮っている。



生活用品通販の偽サイトに注意 消費者庁、転売シーズンで
消費者庁 News Release
人気アウトドア用品公式通販販売サイトを装った偽サイトに関する注意喚起

評価

WCSの性能評価

スバック等を考慮して超概算で試算すると、速度は先行研究の約500倍・既存研究の約24倍と推察されデータ取得率も先行研究の約18倍・既存研究の約2倍と大きく改善

項目	先行研究	本研究	Zowallaらの研究
仮想マシン台数	1	1	22
CPU	Intel Core9-10900	Intel Xeon E-2324G	Intel Xeon E5-2689
CPUコア数	10	2	8
メモリ	16 GB	32 GB	256 GB
データ取得速度	0.03 html/sec	7.58 html/sec	7~10 html/sec
データ取得率	2.37%	43.51%	19.76%

関連研究と本研究

関連研究

偽サイト識別

- 識別手法の研究は多数
- データ収集はスコープ外

WebCrawling

- 長年に渡って、研究事例は多数
- マンスバックを考慮した研究例なし

本研究

低スバック環境^{*1}でも効率的に動作するWebCrawlingと高速かつ高精度なMachine Learning^{*2}を組み合わせた偽ショッピングサイト自動検出システム^{*3}を実社会に適用

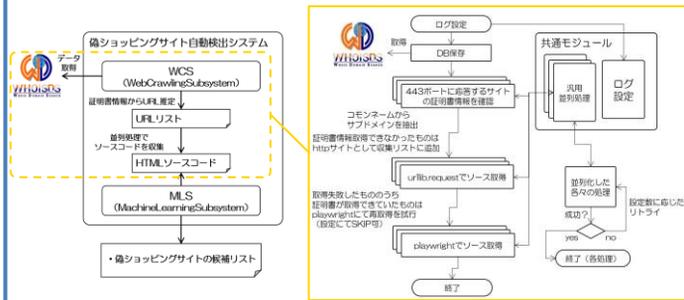
目的

偽ショッピングサイト脅威の低減・無効化
具体的にはサイバーパトロールの業務効率化を目指す

※1：中小規模な研究機関や官公庁では、何十台ものマシンで並列処理を行う環境の用意が困難
 ※2：ISEC（業原氏）から研究を引き継いだJC3で作成したプログラムを改修して実験
 ※3：新規登録ドメインに着目したシステム構想は、ISEC（加藤氏）による先行研究による提案

システム設計

WCSが並列処理でデータを収集、MLSが偽ショッピングサイトの判定^{*5}



※5：WebCrawlingSubsystemの略でWCS、MachineLearningSubsystemの略でMLSと呼称する。MLSの設計はJC3に行っているため、詳細を省略する。

システム全体の評価

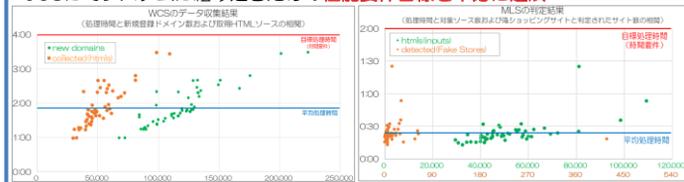
サイバーパトロールにおいて最も時間を要していた、クロールからWebサイトの判定を一気通貫で自動化することに成功し
・約2~4人日/月の工数削減・約3.5倍~13倍の検出効率向上の見込み



項目	学生ボランティア	有識者	本システム
サイバーパトロール	100 min.	50 min.	0 min.
とりまとめ、報告	20 min.	20 min.	20 min.
検出数 (FakeStores)	10	20	21
工数	5.00 人日	2.92 人日	0.83 人日
検出効率 (FakeStores/min)	0.08	0.29	1.05

結果

JC3にてシステムに組み込むための性能要件目標を十分に達成



まとめ

成果 JC3の偽ショッピングサイト対策の取り組みとして採用されシステムに組み込まれて稼働中

今後 ・産官学連携プロジェクトとして共同研究を計画
・システムの改善、他の悪性サイトへの横展開

今後の研究案

- URL推定の改善 (サブドメイン: 証明書、コンテンツ: 機械学習)
- TwitterやYahooのトレンドとGoogle Custom Search API等を利用した新規登録ドメイン以外の入カソースの検討
- 検出した偽サイトのライフサイクル分析、証明書情報等の分析
- 証明書情報に着目した、偽サイト識別用ブラウザアドオンの開発