

企業プレスリリースからの サイバーインシデント情報の 自動収集と分析

明治大学総合数理学部

池上 和輝

研究背景

- 不正アクセスや内部犯行などによる情報漏洩の増加

2014年ベネッセ

- 企業の被害
 - データの損失・破損
 - 事業妨害
 - 損害賠償
 - 広報活動

- これらの脅威への対策を行うために、多くのインシデント情報を収集し分析する必要がある

後、エアバスへの違約金「直結するわけではなく、る契約をエアバスと結んを「相当額負担せざるを得ない可能性がある」と、これは解消される。今回、ことなどを理由にエアバスとして今回、リスクを明示。不採算の地方空港からのスが契約解除を通告し、エアバスからの解 撤退や金融機関からの借 約700億円の違約金を約通知を受け、29日に開 入れなどで対応する方 求める意向とみられるいた会見で西久保慎一社 針もあわせて発表した。スカイマークは「違約金は「資金繰りに問題は 380を総額1915億 は合理性がなく、法的手 必しも破綻リスクに 円（現在価格）で購入す

ベネッセ 赤字136億円
4～6月 情報漏洩で特損260億円

ベネッセホールディングで、4～6月期として初に与える影響を見積もれグスが31日発表した2014年4～6月期の連結 最終赤字になる。通信 ないとして15年3月期の14年4～6月期の連結 講座などの顧客情報の漏 業額予想を取り下げた。決算は、136億円の最 洩で、おわびにかかる 特別損失の内訳は顧客終赤字になった。前年同 用など260億円の特別 への補償に200億円、期は26億円の最終赤字 損失を計上。問題が業績 おわび文書の発送や事件

先行研究・問題点

先行研究

- 昨年一つのメディアから手動で収集(2017)

JNSA	本調査	共通
788	279	145

JNSA(日本ネットワークセキュリティ協会)

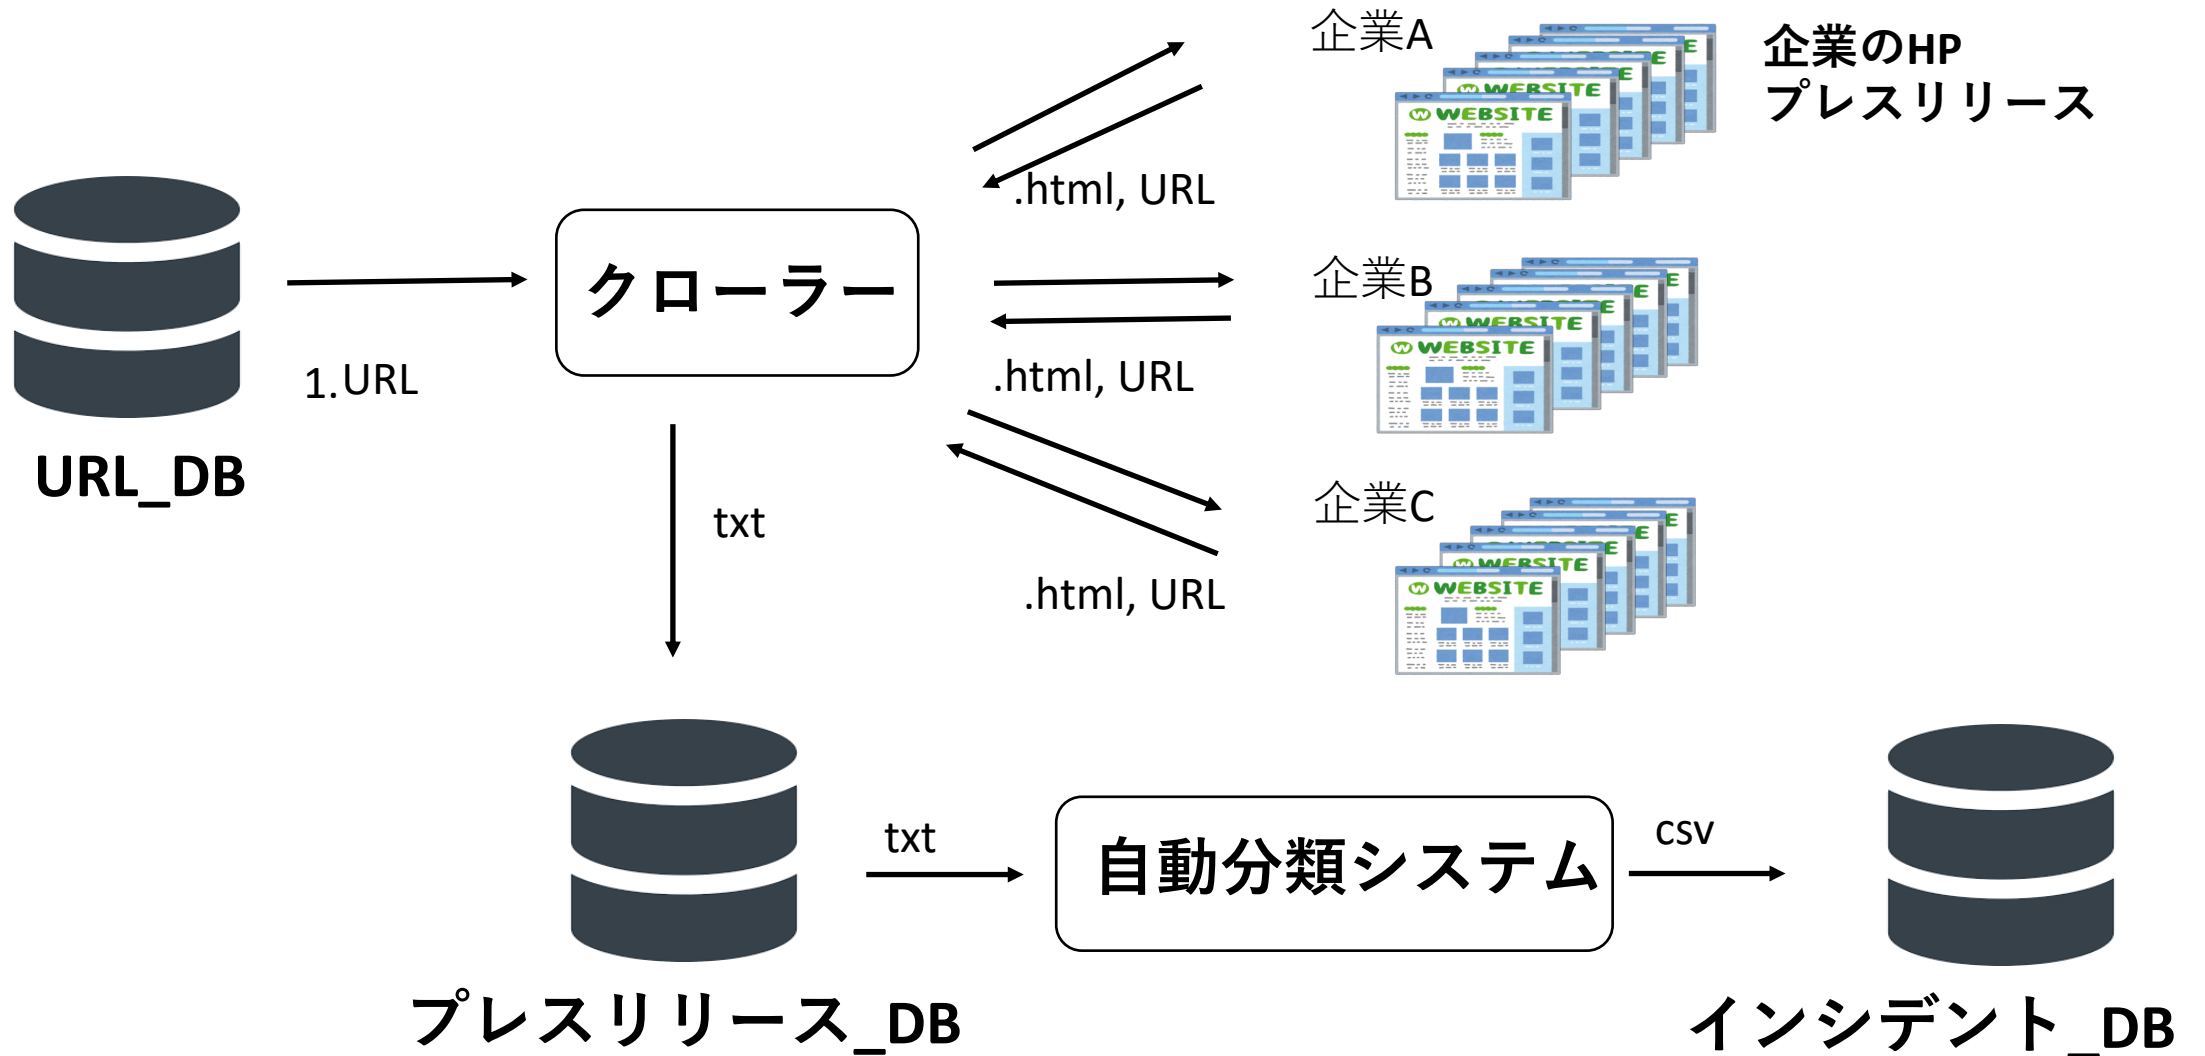
問題点

- 新聞やネット記事を元にする時、網羅的に収集できない可能性がある。
- 人手を使った収集は、コストと時間がかかる。

研究目的・解決方法

- 研究目的
 - メディアなどの偏りなく、網羅的にインシデントを自動収集・分類すること
- 解決方法
 - クローラー・自動分類システムの開発
 - 既存のインシデントデータセットとの比較による評価

システムの全体構成図



自動分類システム(例)

記事(入力)

特徴語の出現頻度比較

2019/2/2
A社の所有するパソコンに不正アクセスがあったことを確認した。
約3000件の個人情報流出した可能性がある。

	入力	人的ミス	不正アクセス	内部犯行
紛失	0	3	0	0
不正アクセス	1	0	2	0
パソコン	1	1	1	4
委託	0	1	1	3
メールアドレス	0	2	0	0

cos類似度

0.33

0.87*

0.45

正規表現により抽出

出力：日付：2019/2/2，規模：3000，原因：不正アクセス

JNSAデータセットの取得項目比較

インシデントリリース(入力)

取得項目(出力)

株式会社ディー・エヌ・エー

2016/04/01

DeNAが運営している「Mobage」において、第三者が「Mobage」ユーザに成りすまし、不正にログインしたと思われる事象が判明した。不正ログインの確認されたID件数 最大104,847件

	抽出結果	正確(JNSA)
企業名	ディー・エヌ・エー	ディー・エヌ・エー
業種	情報通信・サービス その他	情報通信業
日付	2016/04/01	2016/04/01
被害人数	104847	104847
漏洩原因	不正アクセス	不正アクセス
インシデント 内容要約	未定義	有
参照記事のURL		
社会的責任度		普通
漏洩情報区分		個人情報
漏洩経路		インターネット
事後対応		普通

収集結果・JNSAとの比較

・収集結果


企業数	期間	取得記事数	インシデント数	インシデント記事割合
537	2004/10/1~ 2018/11/2	17,957	191	(0.01)

・比較

	JNSA	本調査	共通
企業数	65	34	23
インシデント数	251	141	80

インシデント数はJNSAの約6割

経年変化の比較



共通のインシデントと独自のインシデント例

サイバーエージェ
ント

2010/01/01

不正アクセスによ
り450件のID、パ
スワードが流出し
た可能性がある

JNSA独自

GREE株式会社

2016/12/27

GREEが運営する
「GREE」およびス
マートフォン向け
ゲームアプリを管
理しているシステ
ムに対して、不正
なアクセスがあっ
たことが判明

本調査独自

株式会社ディー・
エヌ・エー

2016/04/01

不正にログインと
思われる事象が判
明した。
不正ログインの確
認されたID件数
最大104,847件

共通

自動分類の結果

$$\text{適合率} = \frac{\text{正しく要素を抽出できたインシデント}}{\text{収集した全インシデント}}$$

	日付	被害人数	漏洩原因	日付&規模&原因
適合率	0.882	0.792	0.719	0.505

各要素はそれぞれ**7割以上**の適合率で分類できた
すべての要素を合わせると約5割

まとめ

- クローラーにより**191**のインシデント記事を収集した
- **2013年以降**ではJNSAと同等のインシデントを収集できた
- 独自のインシデントには、不正アクセスのような悪意のあるインシデントも含まれていた
- 要素別の分類では全て7割を超えた適合率で抽出した

収集できなかったリリースに関して

未収集インシデント	リリース有	リリース無
171	37	134

- HPに存在するものは、クロールする階層が足りなかった。
- 収集できなかった約8割はウェブサイト情報になかった。

原因推定の誤判定について

推定 結果	紛失・ 置忘れ	管理ミス	盗難	誤操作	不正アクセス	ワーム・ウイルス	その他
紛失・置忘れ	53	9	1	0	0	0	2
管理ミス	5	11	1	0	0	0	0
盗難	3	2	29	0	0	0	4
誤操作	0	0	0	12	2	0	1
不正アクセス	0	0	0	1	10	1	2
ワーム・ウイルス	0	0	0	0	1	5	1
その他	0	1	0	0	4	2	8

手動とクローラーの時間比較

- 10企業について、プレスリリースから2016年のインシデント情報(企業名, 業種, 日付, 規模, 原因)を抽出しcsvに落とす

手動	クローラー
26分37秒	30分8秒

- クローラーの方が時間がかかった。。。