

# Os meus dados de fato vazaram? Uma análise de serviços que monitoram vazamentos de dados na Internet (versão estendida)\*

Ariel Góes de Castro<sup>1</sup>, Felipe Antunes Quirino<sup>1</sup>,  
Francisco Germano Vogt<sup>1</sup>, João Otávio Chervinski<sup>3</sup>, Diego Kreutz<sup>1,2</sup>, Pablo Viegas<sup>2</sup>

<sup>1</sup>Curso de Ciência da Computação (CC)  
Laboratório de Estudos Avançados (LEA)  
Universidade Federal do Pampa (UNIPAMPA)

<sup>2</sup>Mestrado Profissional em Engenharia de Software (MPES)  
Universidade Federal do Pampa (UNIPAMPA)

<sup>3</sup>Faculty of Information Technology (FIT)  
Monash University

{agdecastro, felipeantunesquirino, franciscogermanovogt}

@alunos.unipampa.edu.br, joao.massarichervinski@monash.edu

kreutz@unipampa.edu.br, pablo.viegas@gmail.com

**Abstract.** *The number of people who make use of online services is growing rapidly. The majority of the online services collect and store private data belonging to their users. Collected data includes access credentials (username and password), information about credit cards, among other types of personal data. Because of this, such services are frequently targeted by cybercriminals whose goal is to steal data. As a result, the number of reported data leaks has been growing at a fast pace. In order to check whether their data has been made public or not, users can resort to online services, also known as data breach monitors, specialized in gathering leaked data, such as Avast Hack Check, Have I Been Pwned and Firefox Monitor. This work analyzes the data provided by these online services in order to verify the reliability of the results provided to the end-users and their consistency across all investigated data breach monitors. The results show that nearly 50% of the leaked credentials, disclosed in plaintext, have in fact been used the interviewed users. In addition, by taking into account the data breaches listed by the Firefox Monitor, the most frequently leaked kind of data are: (a) email addresses (present in 100% of the data breaches); (b) passwords (78%); (c) usernames (48%); (d) IP addresses (45%); (e) person names (45%) and (f) telephone numbers (27%).*

**Resumo.** *O número de usuários de serviços online não para de crescer. A maioria destes serviços armazena informações sensíveis dos usuários, como credenciais de acesso (login e senha), dados de cartões de crédito, entre outras informações pessoais. Devido a isto, estes serviços tornaram-se alvos frequentes de cibercriminosos. O resultado é um número e volume crescentes de vaza-*

---

\*Este artigo é uma versão estendida do paper [de Castro et al. 2019], originalmente publicado no WR-Seg 2019 e selecionado entre os melhores trabalhos do evento para publicação em revista.

*mentos de dados sensíveis. Para verificar se seus dados foram vazados na Internet, usuários podem recorrer a serviços online especializados, como o Avast Hack Check, o Have I Been Pwned e o Firefox Monitor, que coletam e catalogam dados de vazamentos ocorridos. O objetivo deste artigo é analisar os dados destes serviços online e verificar a consistência e o nível de confiabilidade das informações apresentadas aos usuários. Os resultados indicam que aproximadamente 50% das credenciais apontadas como vazadas, divulgadas em texto plano, haviam de fato sido utilizadas pelos usuários entrevistados. Além disso, analisando os dados publicados pela plataforma Firefox Monitor, pode-se concluir que os tipos de dados mais vazados são: (a) endereços de email (ocorrem em 100% dos vazamentos); (b) senhas (78%); (c) nome de usuário (48%); (d) endereços de IP (45%); (e) nome (45%); e (f) número de telefone (27%).*

## **1. Introdução**

A segurança e a privacidade no armazenamento de informações sensíveis, como email, credenciais de acesso, CPF e outros dados privados, é de interesse da maioria dos usuários de serviços online. Ao fornecer este tipo de informação para uma empresa, o usuário deposita a sua confiança nos sistemas da entidade. Consequentemente, a segurança das informações armazenadas deveria ser uma das maiores prioridades das empresas, visto que um vazamento de dados prejudica sua reputação, pode causar a redução de seu valor de mercado [Neate 2018, Machado et al. 2019b, Machado et al. 2019a] e até mesmo levar a pedido de proteção contra falência, como foi o caso recente da empresa AMCA nos EUA [Osborne 2019].

Infelizmente, os dados dos usuários nem sempre são tratados e armazenados levando em consideração aspectos de segurança e privacidade. Uma prova disto foi a publicização da “Collection #1”, nome dado a um conjunto de mais de 773 milhões de endereços de emails e 21 milhões de senhas únicas. Esse banco de dados foi divulgado publicamente, de uma única vez, em janeiro de 2019 [Hunt 2019]. Este incidente, somado a muitos outros como os vazamentos de dados da Yahoo [Huang et al. 2018], do Facebook [Turner 2019], da British Airways [News 2019], da Quest Diagnostics [McKay 2019] e de várias outras empresas [Machado et al. 2019b, Machado et al. 2019a], expõe as dados sensíveis dos usuários, colocando-o em risco uma vez que agentes maliciosos frequentemente utilizam estes dados para realizar golpes e novos roubos de informação.

Devido ao crescente número de incidentes de segurança [Machado et al. 2019b], estão sendo criadas ferramentas e modelos, como o WCGM [Lu et al. 2018], que utilizam grafos com pesos e técnicas de aprendizado de máquinas para classificar os vazamentos de dados de forma automática. Entretanto, no caso do WCGM, apesar de conseguir analisar uma grande quantidade de dados, o modelo apresenta um grande número de falsos positivos. Métodos específicos de detecção de vazamentos também tem sido propostos na literatura, como os algoritmos para reconhecer padrões em dados e detectar o vazamento de informações sigilosas com um baixo número de falso positivos [Shu et al. 2015]. Dois algoritmos, um de amostragem e um de alinhamento de sequências, são capazes de identificar segmentos de informações vazadas e detectar até mesmo vazamentos parciais de dados [Shu et al. 2015]. Entretanto, nenhum dos trabalhos encontrados na literatura investiga a qualidade e corretude dos dados de plataformas online de consulta de dados

vazados.

As plataformas online Have I Been Pwned<sup>1</sup>, Avast Hack Check<sup>2</sup> e Firefox Monitor<sup>3</sup> foram desenvolvidas para permitir aos usuários, de uma forma simples e rápida, verificar se seus endereços de email (e respectivos dados pessoais, como credenciais) estão contidos em bases de dados que monitoram e agregam informações de vazamentos de dados. A Avast Hack Check notifica por email os usuários quando suas senhas, utilizadas nos mais diversos tipos de sites e sistemas online, são vazadas. Entretanto, um dos desafios destas plataformas está relacionado à qualidade e a confiabilidade dos dados, isto é, determinar se o vazamento de fato ocorreu e se os dados estão corretos.

Este trabalho tem como principal objetivo avaliar a qualidade e a confiabilidade dos resultados apresentados nas buscas das plataformas Have I Been Pwned, Avast Hack Check e Firefox Monitor. Apesar de a plataforma do Firefox Monitor utilizar a base de dados do Have I Been Pwned, ela disponibiliza detalhes dos vazamentos, como nome da empresa, data, número de contas comprometidas e tipos de dados comprometidos. Estes dados serão utilizados para realizar uma análise estatística dos vazamentos registrados nos últimos doze meses.

Esta pesquisa pode ser dividida em três etapas. Primeiro, foi realizado um levantamento e análise de dados, utilizando um conjunto limitado e conhecido de usuários, para verificar se as senhas informadas como vazadas já foram, de fato, utilizadas pelos respectivos usuários. Segundo, as estatísticas das duas plataformas foram analisadas a fim de encontrar similaridades. Finalmente, foram realizados também testes utilizando uma lista pública de 50.664 emails encontrados na Web para verificar se as estatísticas dos vazamentos é similar a distribuição observada nos casos anteriores.

## 2. Metodologia

**Coleta dos dados.** As informações reunidas para a análise foram coletadas a partir de três fontes distintas. Os conjuntos de dados são compostos por endereços de email de usuários, que são a informação utilizada pelas ferramentas analisadas para verificar a ocorrência de vazamentos de dados. Os três processos de coleta são descritos a seguir.

*Conjunto de Dados I:* A primeira coleta de dados consistiu na aquisição de dados de 50.664 endereços de email disponibilizados na Internet. Este conjunto de dados é composto por endereços de email cadastrados em um serviço de *marketing* online. Esta coleção de endereços favorece a visualização da distribuição dos vazamentos considerando que ela contém informações de usuários (emails) que acessam vários serviços distintos.

*Conjunto de Dados II:* A segunda coleta consiste em um conjunto de 108 endereços de email conhecidos, obtidos a partir de uma lista de contatos de uso pessoal. Isto garante que são emails efetivamente utilizados. Este conjunto de dados permite comparar os resultados estatísticos das plataformas entre uma lista de emails conhecidos e uma de endereços desconhecidos (Conjunto de Dados I).

*Conjunto de Dados III:* A terceira coleta de dados foi realizada com a ajuda de vo-

---

<sup>1</sup><https://haveibeenpwned.com/>

<sup>2</sup><https://www.avast.com/hackcheck>

<sup>3</sup><https://monitor.firefox.com>

luntários. Primeiro, foi criado e disponibilizado um formulário online, utilizando o serviço Google Forms, para coletar informações sobre os vazamentos de dados dos usuários. Segundo, cada participante acessa a plataforma Avast Hack Check para verificar se seus dados foram vazados. A Avast Hack Check envia um email com os detalhes dos vazamentos, incluindo sites, senhas e outros detalhes. Terceiro, o participante informa no formulário online se as senhas identificadas pela plataforma estão corretas, isto é, são ou já foram utilizadas por ele.

**Processamento e análise dos dados.** Para automatizar o processo de verificação dos endereços de email dos três conjuntos de dados, foram criados dois *scripts*. Os *scripts* preenchem automaticamente os formulários online da plataforma Have I Been Pwned, coletam os resultados e geram os gráficos estatísticos correspondentes (ver detalhes dos gráficos e análise na Seção 3).

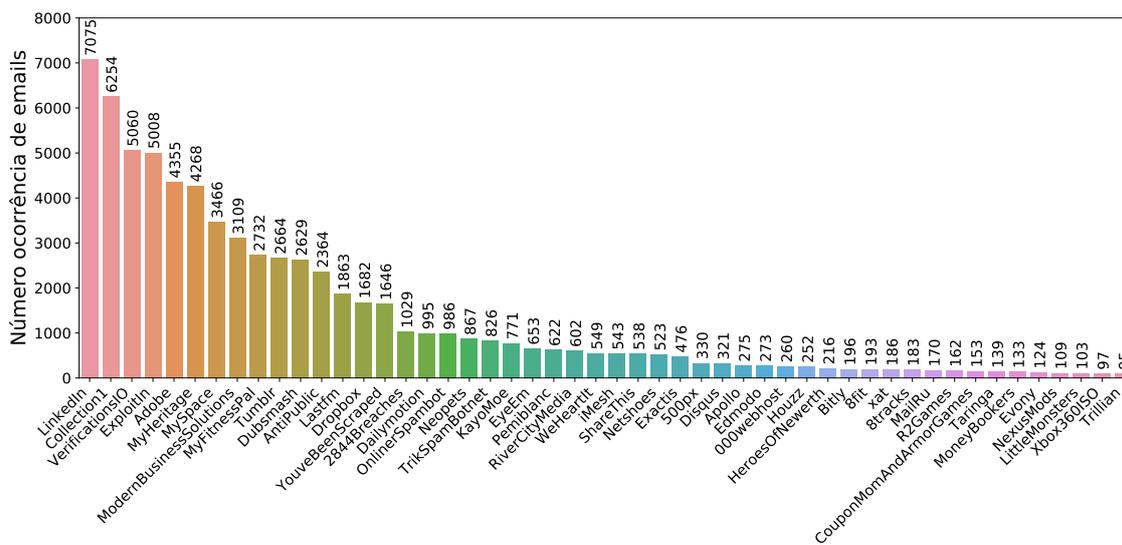
### 3. Resultados

#### 3.1. Estatísticas do Conjunto de Dados I

A Figura 1 apresenta os 50 sites com maior quantidade de dados vazados levando em consideração os 50.664 emails do primeiro conjunto de dados. Como pode ser observado, sites conhecidos e amplamente utilizados, como LinkedIn, Adobe, MySpace e Tumblr, estão entre os 10 com o maior número de dados vazados. Ainda, para este conjunto de dados, o LinkedIn, sozinho, vazou dados de cerca de 13,5% dos emails testados.

Além de apontar qual serviço vazou os dados (e.g., LinkedIn), a plataforma Have I Been Pwned indica se o email vazado pertence a alguma coleção. Neste caso, segundo o número de incidências, podem ser destacadas as duas principais coleções atuais, a Collection #1 e a Verifications.io.

**Figura 1. 50 maiores vazamentos do conjunto de 50.664 e-mails**

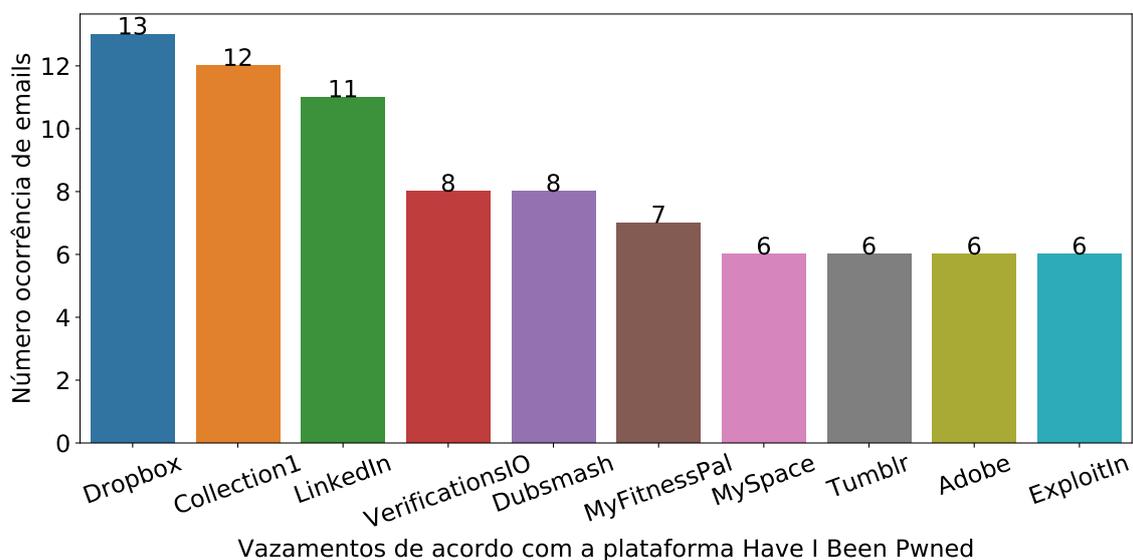


Vazamentos de acordo com a plataforma Have I Been Pwned

### 3.2. Estatísticas do Conjunto de Dados II

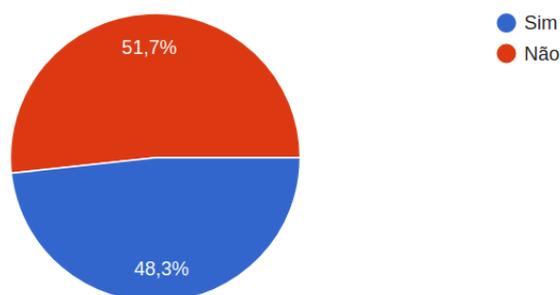
A Figura 2 apresenta as 10 principais fontes de vazamento de dados para o segundo conjunto de dados (e-mails de listas de contatos dos autores deste estudo). Como pode ser observado, o Dropbox representa a maior fonte de vazamento, com 13 e-mails. Vale ressaltar que, assim como no primeiro conjunto de dados, os sites LinkedIn, Adobe, MySpace, Tumblr, entre outros, aparecem novamente entre os 10 com o maior número de dados vazados. Esta similaridade aponta para uma tendência, que aparentemente independe do conjunto de dados de entrada (emails) utilizado para alimentar as duas plataformas.

Figura 2. 10 maiores vazamentos do conjunto de 108 e-mails.



### 3.3. Estatísticas do Conjunto de Dados III

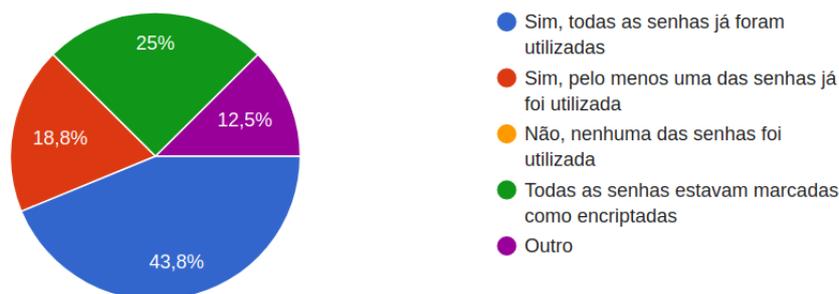
Figura 3. Porcentagem de usuários com credenciais vazadas.



Os dados desta seção correspondem a estatísticas e análises realizadas na plataforma Avast Hack Check. A Figura 3 resume o resultado da pesquisa online com os usuários. Como pode ser observado, praticamente 50% dos usuários afirmaram que suas credenciais já foram, ao menos uma vez, vazadas segundo os dados apresentados pela plataforma Avast Hack Check. A porcentagem de confirmações é alta e assegura que, de fato, há dados verídicos e corretos na plataforma. Entretanto, obviamente, isto não

significa que deve-se assumir que os dados são todos de qualidade e confiáveis. É sabido que é relativamente comum existir lixo (e.g., dados involuntariamente corrompidos, dados voluntariamente corrompidos, dados forjados) em meio a dados vazados na Internet.

**Figura 4. Informações sobre as senhas vazadas**



A Figura 4 apresenta dados complementares aos apresentados na Figura 3. Como pode ser observado, 43,8% dos participantes do levantamento de dados informou que todas as senhas apresentadas pela plataforma condiziam com senhas que já haviam sido utilizadas em algum momento. Em segundo lugar, 25% participantes informaram que todas as senhas estavam cifradas (e.g., vazamento de senha cifrada do Dropbox). Consequentemente, não foi possível verificar se as senhas eram, ou não, corretas. Em terceiro lugar, 18,8% dos entrevistados confirmaram que pelo menos uma das senhas apresentadas foi, de fato, utilizada. Consequentemente, do total de participantes, 62,6% (43,8% + 18,8%) confirmaram que pelo menos uma de suas senhas já foi vazada. Finalmente, 12,5% informaram outra situação (e.g., nenhuma senha foi apresentada pela plataforma, as senhas eram muito antigas e repetiam-se). A Figura 5 apresenta dois exemplos de *feedback* dos participantes.

**Figura 5. Relatos sobre os vazamentos reportados**

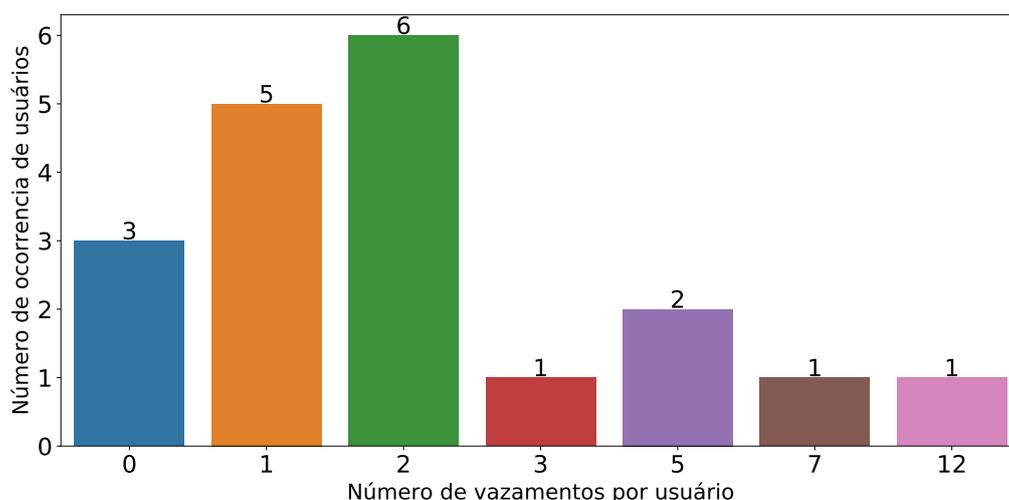
As senhas eram muito antigas e se repetiam  
Uma senha não utilizada (1b143a70e081964779533cb81a8275af...) e as demais aparecem criptografadas.

A Figura 6 resume o número de contas comprometidas. Cada conta corresponde a um site/sistema distinto. Enquanto que a maioria dos participantes teve de 0 a 2 contas comprometidas e dois tiveram 7 e 12, respectivamente. Isto reforça a tendência apresentada no gráfico da Figura 1, onde o número de vazamentos é concentrado em aproximadamente 15 sites. Para os demais sites, o número de vazamentos reduz rapidamente.

### 3.4. Estatísticas do Firefox Monitor

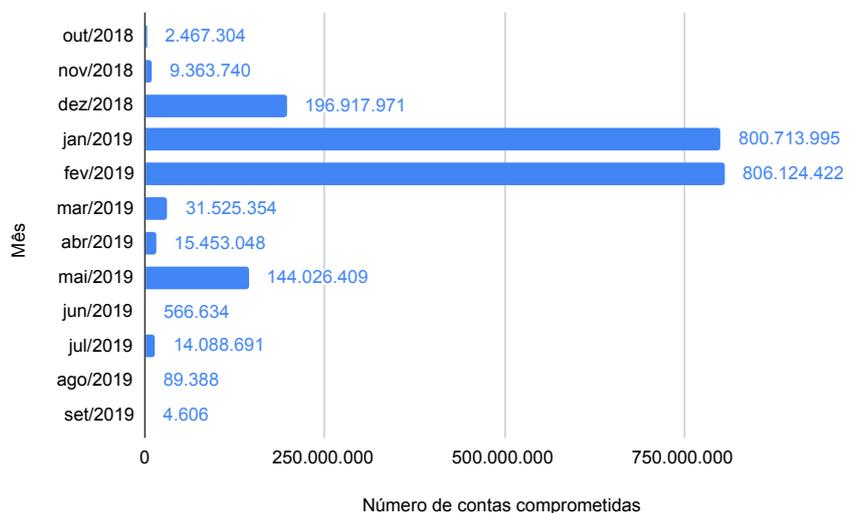
Segundo os dados apresentados pela plataforma Firefox Monitor [Mozilla 2019], durante os últimos doze meses foram divulgados e investigados pelo menos 37 grandes vazamentos de dados, totalizando mais de 2 bilhões de contas comprometidas. No gráfico da Figura 7 são apresentadas as estatísticas mês a mês entre outubro de 2018 a setembro de 2019. Como pode ser observado, aparentemente, os meses com o menor volume de

**Figura 6. Número de cadastros vazados**



dados comprometidos são agosto e setembro de 2019. Entretanto, vale ressaltar que a atualização das bases de dados de plataformas como a Firefox Monitor, com informações de vazamentos novos ou recentes, é lenta. O tempo entre o vazamento dos dados e sua publicização pode ser longo. Portanto, pode-se esperar que estes números aumentem significativamente, como indicado pelos números apresentados em pesquisa recente [Machado et al. 2019a].

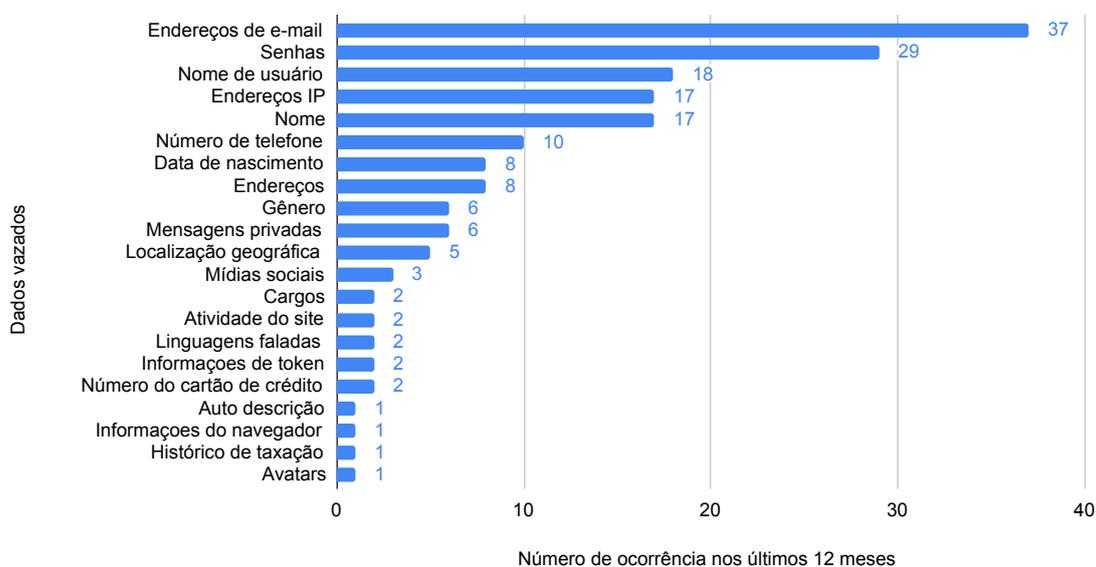
**Figura 7. Quantidade de contas comprometidas nos últimos 12 meses**



Segundo as estatísticas (figura 6), os meses que bateram recordes de volume de vazamentos registrados são dezembro de 2018 a fevereiro de 2019. Em dezembro de 2018 o volume de dados vazados ficou próximo de 200 milhões de registros. Já em janeiro e fevereiro de 2019 o número de registros vazados ultrapassou a marca de 800 milhões. O que levou a essa anomalia (volume acentuado de dados vazados) foram duas grandes coleções de dados divulgadas na Internet, a Collection #1, com 770 milhões de

emails e senhas únicas, e a Verifications.io, com 760 milhões de registros contendo data de nascimento, endereços de e-mail, localização geográfica, endereços IP, nomes, número de telefone e endereço.

**Figura 8. Tipos de dados mais vazados nos últimos 12 meses**



O gráfico da Figura 8 apresenta os tipos de dados mais frequentemente vazados de acordo com os 37 vazamentos de dados analisados. Como pode ser observado, endereços de email estão presentes em 100% dos vazamentos. Em segundo lugar vem as senhas, que fazem parte de 78% dos vazamentos de dados. Na terceira, quarta e quinta posições, praticamente com o mesmo número de incidências, vem nome de usuário, endereços IP e nome. Vale a pena também observar que 45% dos vazamentos comprometem dados sensíveis de localização (e.g., endereços IP) dos usuários.

#### 4. Discussão

Vazamento de dados é um tema atual e muito importante [Machado et al. 2019b]. Um vazamento de dados pode afetar um conjunto de usuários (e.g., usuários de um determinado aplicativo) até uma população inteira. Por exemplo, recentemente vazaram os dados de toda a população do Equador [Machado et al. 2019a]. Num caso similar, na Bulgária, um hacker roubou os dados de aproximadamente 70% da população. O número de incidentes de segurança e vazamentos de dados de grande impacto vem crescendo rapidamente nos últimos anos [Machado et al. 2019b, Machado et al. 2019a].

Devido ao cenário atual crônico e com tendência de piorar, alterações na legislação em diferentes partes do mundo estão tendo como pauta central a proteção aos dados do usuário. Na Europa, está em vigor desde a metade de 2018 o Regulamento Geral de Proteção de Dados (GDPR). Esta lei foca na privacidade e segurança digital dos consumidores, obrigando as empresas a manter níveis elevados de segurança e divulgar qualquer informação de violação de seus bancos de dados em até 72 horas. A empresa que descumprir essas exigências poderá ser multada em até 4% de sua receita anual ou 20 milhões de euros, aquele que for o maior valor [Regulation 2016].

No Brasil, também em 2018, foi aprovado o projeto de lei criando a Lei Geral de Proteção de Dados Pessoais (LGPD). O texto é inspirado na legislação europeia e também estabelece que empresas que tenham atividade centrada no tratamento sistemático de dados pessoais sejam obrigadas, entre outras coisas, a ter um Encarregado pelo Tratamento de Dados Pessoais, ou *Data Protection Officer* (DPO). As empresas brasileiras tem até o final de 2020 para se adaptar às novas normas [Brasil 2019].

Apesar das alterações legislativas em andamento, é importante reconhecer a importância das plataformas que buscam apresentar alternativas aos usuários para verificar se seus dados vazaram. Plataformas como a Avast Hack Check, o Have I Been Pwned e o Firefox Monitor. Estas são ferramentas importantes para publicizar vazamentos e permitir o fácil e rápido acesso aos dados vazados. Estas plataformas possuem também um caráter educacional, divulgando e reforçando a importância da segurança da informação e de sistemas. Elas reforçam as recomendações necessárias no cuidado com dados pessoais, seja pelo usuário, mantendo suas senhas seguras e realizando atualizações frequente de software, seja pelas empresas e departamentos técnicos de tecnologia da informação, atualizando políticas e técnicas para proteção de dados.

## 5. Considerações e Trabalhos futuros

Com base nos resultados apresentados, pode-se concluir que a distribuição de vazamentos das plataformas, obtida nos testes com 50.664 emails não verificados, é similar a distribuição obtida com a lista de 108 emails verificados. Isso é um indício de que os resultados dos testes correspondem a realidade.

Segundo as estatísticas apresentadas, 62,6% dos usuários já utilizaram pelo menos uma das senhas vazadas. Isto demonstra que boa parte dos dados apresentados pelas plataformas Have I Been Pwned e a Avast Hack Check correspondem a realidade. Vale ressaltar que este percentual poderia ser ainda maior se todas as senhas vazadas estivessem decifradas, isto é, em formato textual inteligível, permitindo assim a sua validação. Entretanto, em alguns vazamentos, as senhas vazadas estão cifradas, o que impede a análise e confirmação por parte do usuário.

Com base nos dados divulgados pela plataforma Firefox Monitor, os tipos de dados mais vazados são: (a) endereços de email (ocorrem em 100% dos vazamentos); (b) senhas (78%); (c) nome de usuário (48%); (d) endereços de IP (45%); (e) nome (45%); e (f) número de telefone (27%). Outros dados bastante sensíveis, como localização geográfica, número de cartões de crédito, e mensagens privadas, ocorrem com menor frequência.

Como trabalhos futuros, podem ser listados: (a) realizar um levantamento de dados mais extensivo, isto é, com um grupo maior de participantes e com questionários mais detalhados; (b) analisar bases de emails maiores; (c) identificar estatisticamente se os emails possuem, de fato, contas nos sistemas indicados (e.g., LinkedIn, MySpace, Dropbox); (d) identificar a porcentagem de falsos positivos das plataformas; (e) cruzar dados com outras fontes, como relatórios técnicos de vazamentos de dados; e (f) avaliar outras plataformas, como a HPI Identity Leak Checker<sup>4</sup>.

---

<sup>4</sup><https://sec.hpi.de/ilc/>

## Referências

- Brasil, R. F. d. (2019). Lei nº 13.853 de 8 de julho de 2019. altera a lei nº 13.709, de 14 de agosto de 2018, para dispor sobre a proteção de dados pessoais e para criar a autoridade nacional de proteção de dados; e dá outras providências. *Diário Oficial da República Federativa do Brasil*.
- de Castro, A. G., Quirino, F., Vogt, F., Kreutz, D., and Chervinski, J. O. (2019). Os meus dados de fato vazaram? Uma análise de serviços que monitoram vazamentos de dados na Internet. In *4o Workshop Regional de Segurança da Informação e de Sistemas Computacionais*, Alegrete-RS, Brasil. <http://errc.sbc.org.br/2019/wrseg/papers/castro2019os.pdf>.
- Huang, X., Lu, Y., Li, D., and Ma, M. (2018). A novel mechanism for fast detection of transformed data leakage. *IEEE Access*, 6:35926–35936.
- Hunt, T. (2019). Have i been pwned? <https://haveibeenpwned.com>.
- Lu, Y., Huang, X., Ma, Y., and Ma, M. (2018). A weighted context graph model for fast data leak detection. In *IEEE Int. Conf. on Communications (ICC)*, pages 1–6. IEEE.
- Machado, R., Kreutz, D., Paz, G., and Rodrigues, G. (2019a). Vazamentos de Dados: Histórico, Impacto Socioeconômico e as Novas Leis de Proteção de Dados. [http://arxiv.kreutz.xyz/reabtict2019\\_data\\_leaks\\_ev1.pdf](http://arxiv.kreutz.xyz/reabtict2019_data_leaks_ev1.pdf).
- Machado, R. B., Kreutz, D., Paz, G., and Rodrigues, G. (2019b). Vazamentos de Dados: Histórico, Impacto Socioeconômico e as Novas Leis de Proteção de Dados. In *4o Workshop Regional de Segurança da Informação e de Sistemas Computacionais*, WRSeg '19. SBC. <https://errc.sbc.org.br/2019/wrseg/papers/machado2019vazamentos.pdf>.
- McKay, T. (2019). Lab Testing Giant Quest Diagnostics Says Data Breach May Have Hit Nearly 12 Million Patients. <http://bit.do/e25Ps>.
- Mozilla (2019). Monitor firefox. <https://monitor.firefox.com/>.
- Neate, R. (2018). Over \$119 billions wiped off Facebook's market cap after growth shock. <http://bit.do/e3dwm>.
- News, B. (2019). British Airways faces record £183m fine for data breach. <http://bit.do/e25Q7>.
- Osborne, C. (2019). Data breach forces medical debt collector AMCA to file for bankruptcy protection. <http://bit.do/e25Px>.
- Regulation, G. D. P. (2016). Regulation (EU) 2016/679 of the european parliament and of the council of 27 april 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing directive 95/46. *Official Journal of the European Union (OJ)*, 59(1-88):294.
- Shu, X., Zhang, J., Yao, D. D., and Feng, W.-C. (2015). Fast detection of transformed data leaks. *IEEE Transactions on Information Forensics and Security*, 11(3):528–542.
- Turner, S. (2019). 2019 data breachers - the worst so far. <http://bit.do/e25MP>.