

# Quantificando Vazamento de Informação sobre Estratégias

Mário S. Alvim<sup>1</sup>, Piotr Mardziel<sup>2</sup>, Michael Hicks<sup>2</sup>

<sup>1</sup> Universidade Federal de Minas Gerais  
msalvim@dcc.ufmg.br

<sup>2</sup>University of Maryland, College Park  
{piotrm,mwh}@cs.umd.edu

**Abstract.** *The field of quantitative information flow concerns the rigorous mathematical assessment of the amount of secret information leaked by computational systems. We report first steps towards a formal model for strategic leakage. We generalize the representation of prior adversarial knowledge from a distribution on secrets to a distribution on strategies for generating secrets, which we call an environment. Applying information-theoretic techniques to environments allows us to disentangle information leakage about a secret from leakage about how users generate secrets, i.e., their strategy.*

**Resumo.** *Este resumo reporta primeiros passos na formalização do conceito de vazamento de estratégias. Nós generalizamos a representação do conhecimento prévio de um adversário de uma distribuição de probabilidade sobre os segredos para uma distribuição sobre estratégias que geram segredos, chamando esta nova distribuição de ambiente. Aplicando técnicas de teoria da informação a ambientes, conseguimos distinguir o vazamento de informação sobre segredos do vazamento de informação sobre a maneira como segredos são gerados, i.e., sobre a estratégia.*

## 1. Introdução

O campo de *fluxo de informação quantitativo* (QIF, do inglês *quantitative information flow*) diz respeito à mensuração da informação sigilosa vazada por sistemas computacionais. Baseando-se no rigor matemático da teoria da informação, dois princípios fundamentais de QIF são: (i) um segredo é considerado “seguro” na medida em a distribuição de probabilidade sobre os valores sigilosos tem alta entropia; e (ii) o vazamento de informação de um sistema é uma medida de quanto o comportamento observável do sistema, durante o processamento de um valor sigiloso, degrada a entropia desse segredo. Estes princípios têm sido usados para criar modelos de QIF cada vez mais sofisticados para representar sistemas e medir vazamentos. No entanto, pouca atenção tem sido dedicada a entender as fontes que injetam a entropia inicial na distribuição sobre os segredos.

Muitas vezes, o processo de geração de segredos não é completamente aleatório. Por exemplo, usuários podem ter uma “estratégia” para escolher senhas que seja parcialmente previsível (por exemplo, usando sua data de nascimento), e um adversário pode usar isso para prever senhas futuras. Estudos têm mostrado que forçar usuários a alterar frequentemente suas senhas pode não ser tão benéfico quanto se acreditava [Zhang et al. 2010, Chiasson and van Oorschot 2015]. Além disso, um segredo que varia no tempo e sofre repetidas observações, em alguns casos, pode ser aprendido *mais rapidamente* se for alterado (e observado) mais frequentemente [Mardziel et al. 2014].

Neste resumo investigamos em que medida o conhecimento sobre *estratégias* ajuda o adversário a inferir o segredo. Desenvolvemos um modelo que não considera apenas o espaço de segredos possíveis, mas também o espaço de possíveis estratégias que os geram. Nosso modelo nos permite considerar adversários capazes de aprender a estratégia e quantificar a vantagem que eles obtêm, desacoplando a medida do valor de se aprender a estratégia da medida do valor de se aprender o segredo. No resto deste resumo, apresentamos o nosso modelo inicial e caracterizações de vazamento de estratégias.

## 2. Preliminares

Faremos uma breve revisão de conceitos fundamentais de *fluxo de informação quantitativo* (QIF). Um *adversário* tem apenas informação parcial sobre o valor de um *segredo*, modelada por uma distribuição de probabilidade chamada de *prior*. Denotamos por  $\mathcal{X}$  o conjunto de segredos possíveis e por  $\mathbb{D}\mathcal{X}$  o conjunto de distribuições de probabilidade sobre  $\mathcal{X}$ . Normalmente usamos  $p_X$  para denotar uma *prior*. Uma medida de informação é uma função  $\mathbb{V}:\mathbb{D}\mathcal{X}\rightarrow\mathbb{R}$  com imagem real. Uma medida de informação pode medir *vulnerabilidade* - quanto maior o valor, menos seguro é o segredo - ou *incerteza/entropia* - quanto maior o valor, mais seguro é o segredo. Definições de medidas de informação na literatura variam de acordo com a interpretação operacional da medida. Recentemente, o arcabouço de *g-vulnerability* [Alvim et al. 2012] foi proposto para capturar vários modelos de adversário. Neste artigo vamos utilizar o termo “vulnerabilidade” para medidas em geral, embora as nossas reivindicações também se aplicam a incerteza medidas. Uma *hiper-distribuição* [McIver et al. 2014] (ou *hiper*) é uma distribuição de probabilidade sobre distribuições. Uma hiper sobre o conjunto  $\mathcal{X}$  é do tipo  $\mathbb{D}^2\mathcal{X}$ , significando  $\mathbb{D}(\mathbb{D}\mathcal{X})$ . Usamos  $\Delta$  para denotar uma hiper,  $[\Delta]$  para seu *suporte* (o conjunto de valores com probabilidade não nula), e  $[p_X]$  para hiper puntual associando probabilidade 1 para  $p_X$ .

## 3. Estratégias e sua vulnerabilidade

Esta seção apresenta um modelo que explicita que segredos são gerados pela aplicação de uma estratégia particular, e apresenta generalizações de vulnerabilidade correspondentes.

### 3.1. Vulnerabilidade contextual do segredo

Uma *estratégia* é uma regra probabilística para a geração de segredos, representada por uma distribuição de probabilidade sobre o conjunto  $\mathcal{X}$  de segredos. O conjunto  $\mathcal{S}$  de todas as estratégias é, portanto,  $\mathbb{D}\mathcal{X}$ . Modelamos o *ambiente* em que o segredo é gerado como uma distribuição  $p_S$  sobre o conjunto  $\mathcal{S}$  de estratégias. O conjunto  $\mathbb{D}\mathcal{S}$  de todos os ambientes é o conjunto das distribuições de probabilidade sobre estratégias, ou seja, o conjunto  $\mathbb{D}^2\mathcal{X}$  de hipers sobre  $\mathcal{X}$ . O ambiente representa o espaço de onde estratégias são amostrados. Assumimos que a *prior*  $p_X$  sobre segredos é *consistente* com o ambiente  $p_S$ , isto é, que a *prior* é obtida como o comportamento esperado do ambiente na falta qualquer conhecimento mais refinado sobre estratégia utilizada:  $p_X = \mathbb{E} p_S$ . Caso haja uma única estratégia  $p_X$  para gerar segredos, o ambiente  $p_S$  é a hiper puntual  $[p_X]$ .

Enquanto em modelos tradicionais de QIF o adversário só sabe a *prior*  $p_X$ , consideramos aqui também adversários que conhecem o ambiente  $p_S$ . A vulnerabilidade do segredo para este tipo adversário mais poderoso é definida a seguir.

**Definition 1.** Dada uma medida de informação  $\mathbb{V}$ , a *vulnerabilidade contextual (do segredo)* é uma função  $\mathbb{V}_C:\mathbb{D}^2\mathcal{X}\rightarrow\mathbb{R}$  definida como  $\mathbb{V}_C(p_S) \stackrel{\text{def}}{=} \mathbb{E}_{p_S} \mathbb{V}$  representando a expectativa da vulnerabilidade do segredo quando o ambiente é conhecido pelo adversário.

Nosso primeiro resultado é que um adversário que conhece o ambiente nunca está em desvantagem em relação a um adversário que só conhece a *prior* sobre os segredos.

**Proposition 1.** *Se  $\mathbb{V}$  é uma  $g$ -vulnerability, então  $\mathbb{V}_C(p_S) \geq \mathbb{V}(p_X)$ .*

Além disso, no caso de o ambiente  $p_S$  ser uma hiper puntual  $[p_X]$ , a vulnerabilidade contextual  $\mathbb{V}_C(p_S)$  se reduz a  $\mathbb{V}(p_X)$ .

**Proposition 2.** *Se  $p_S = [p_X]$ , então  $\mathbb{V}_C(p_S) = \mathbb{V}(p_X)$ .*

### 3.2. Segurança real e segurança por agregação

A modelagem do conhecimento do adversário como apenas uma *prior*  $p_X$  ignora como o adversário pode explorar o conhecimento do ambiente  $p_S$  para inferir segredos. Demonstramos este fato com um exemplo em que segredos distribuídos de acordo com uma mesma *prior* apresentam vulnerabilidades contextuais drasticamente diferentes.

Sejam  $\mathcal{X} = \{x_1, x_2\}$  um conjunto de valores secretos binários, e  $\mathcal{S} = \{s_1, s_2, s_3\}$ , um conjunto de possíveis estratégias, onde  $s_1 = [1, 0]$  sempre gera o valor  $x_1$ ,  $s_2 = [0, 1]$  sempre gera o valor  $x_2$  e  $s_3 = [1/2, 1/2]$  gera cada valor com igual probabilidade. Considere dois ambientes  $p_S^1 = [1/2, 1/2, 0]$ , em que as estratégias  $s_1$  e  $s_2$  pode ser adotadas com igual probabilidade,

e  $p_S^2 = [0, 0, 1]$ , em que a estratégia  $s_3$  é sempre adotada. Retratamos tais estratégias e ambientes na Tabela 1. Colunas listam estratégias; o primeiro agrupamento de linhas contém a definição da estratégia (isto é, a probabilidade de cada segredo ser escolhido), o agrupamento seguinte de linhas contém a definição de cada ambiente, um por linha, fornecendo a probabilidade de cada estratégia. Ambos os ambientes produzem a mesma *prior*  $p_X = \mathbb{E} p_S^1 = \mathbb{E} p_S^2 = [1/2, 1/2]$ , assim um adversário que não pode observar a estratégia utilizada obterá a mesma vulnerabilidade prévia em ambos os ambientes. Por exemplo, para a vulnerabilidade de Bayes  $\mathbb{V}^{\text{Bayes}}(p_X) \stackrel{\text{def}}{=} \max_{x \in \mathcal{X}} p_X(x)$ , o adversário obterá uma vulnerabilidade de  $\mathbb{V}^{\text{Bayes}}(p_X) = 1/2$ . No entanto, um adversário que possa aprender a estratégia utilizada obterá diferentes vulnerabilidades do segredo em cada ambiente. No ambiente  $p_S^1$  a vulnerabilidade contextual é  $\mathbb{V}_C^{\text{Bayes}}(p_S^1) = 1/2 \cdot p(s_1) + 1/2 \cdot p(s_2) = 1/2 \cdot 1 + 1/2 \cdot 1 = 1$ , enquanto no ambiente  $p_S^2$  a vulnerabilidade contextual é  $\mathbb{V}_C^{\text{Bayes}}(p_S^2) = 1 \cdot p(s_3) = 1 \cdot 1/2 = 1/2$ . Note que no ambiente  $p_S^2$ , o valor para a vulnerabilidade contextual e vulnerabilidade prévia é o mesmo ( $\mathbb{V}_C^{\text{Bayes}}(p_S^2) = \mathbb{V}^{\text{Bayes}}(p_X) = 1/2$ ), assim um adversário que aprende a estratégia utilizada não terá vantagem sobre um adversário que só conhece a *prior*. Por outro lado, no ambiente  $p_S^1$ , a vulnerabilidade contextual excede a vulnerabilidade prévia ( $\mathbb{V}_C^{\text{Bayes}}(p_S^1) = 1 > 1/2 = \mathbb{V}^{\text{Bayes}}(p_X)$ ), e um adversário que aprende a estratégia utilizada obterá sucesso duas vezes mais frequentemente que um adversário que só conhece a *prior*.

	$s_1$	$s_2$	$s_3$
$x_1$	1	0	1/2
$x_2$	0	1	1/2
$p_S^1$	1/2e1/2e0		
$p_S^2$	0	0	1

**Tabela 1.**

Podemos obter dois *insights* a partir deste exemplo. Em primeiro lugar, *segurança por agregação* ocorre quando a vulnerabilidade contextual excede a vulnerabilidade prévia:  $\mathbb{V}_C(p_S) \gg \mathbb{V}(p_X)$ . Neste caso, o segredo está protegido pela falta de conhecimento por parte do adversário sobre a estratégia utilizada, e se o adversário aprender a estratégia a vulnerabilidade do segredo pode aumentar significativamente. Um exemplo de segurança por agregação é um cenário em que todos usuários escolhem senhas com estratégias determinísticas, mas o adversário não sabe qual usuário está gerando a a senha. Se houver um grande número de usuários, e se são as suas estratégias são variada o suficiente, as senhas podem ser considerados “seguras” apenas no sentido de que o adversário não pode usar o conhecimento sobre o ambiente para identificar a estratégia utilizada.

Por outro lado, *segurança real* ocorre quando vulnerabilidades contextual e prévia têm valores semelhantes:  $\mathbb{V}_C(p_S) \approx \mathbb{V}(p_X)$ . Neste caso, o segredo está protegido pela imprevisibilidade (ou incerteza) no âmbito das estratégias que geram o segredo, e mesmo que a estratégia se torne conhecida pelo adversário, a vulnerabilidade do segredo não irá aumentar significativamente. Um exemplo de segurança real é um sistema de banco em que senhas são escolhidas automaticamente para cada usuário de modo uniforme. Mesmo que o algoritmo seja conhecido do adversário, a vulnerabilidade do segredo não aumenta.

### 3.3. Vulnerabilidade da estratégia

Consideramos agora como o conhecimento de um ambiente afeta o conhecimento do adversário sobre a estratégia a ser utilizada, definindo uma medida  $\mathbb{V}_S(p_S): \mathbb{DS} \rightarrow \mathbb{R}$  da *vulnerabilidade da estratégia*. A ideia central é que  $\mathbb{V}_S(p_S)$  deve refletir a “semelhança” entre as estratégias no suporte de  $p_S$ . Do ponto de vista do adversário, duas estratégias devem ser consideradas “semelhantes” se levarem a “semelhantes” vulnerabilidades do segredo, conforme medido de acordo com uma  $\mathbb{V}: \mathbb{DX} \rightarrow \mathbb{R}$  de interesse. Assim, a vulnerabilidade de um ambiente deve ser mais elevada quando o seu suporte consistir em estratégias semelhantes, e mais baixa quando seu suporte consistir em estratégias muito diferentes. Uma estratégia é, *para fins práticos*, conhecida pelo adversário quando  $\mathbb{V}(p_X) \approx \mathbb{V}_C(p_S)$ , ou, equivalente, quando  $\mathbb{V}(\mathbb{E} p_S) \approx \mathbb{E}_{p_S} \mathbb{V}$ .

**Definition 2.** Se  $\mathbb{V}$  é uma medida de vulnerabilidade, então a *vulnerabilidade da estratégia* é a relação  $\mathbb{V}_S(p_S) \stackrel{\text{def}}{=} \mathbb{V}(\mathbb{E} p_S) / \mathbb{V}_C(p_S)$ . A razão é invertida para medidas de incerteza.

Note que temos sempre  $0 \leq \mathbb{V}_S(p_S) \leq 1$  (pela Proposição 1), e  $\mathbb{V}_S(p_S)$  é máxima quando  $\mathbb{V}(\mathbb{E} p_S) = \mathbb{V}_C(p_S)$ . Além disso, note que a definição é consistente com a de decomposição vulnerabilidade prévia no produto de vulnerabilidade estratégica e vulnerabilidade contextual:  $\mathbb{V}(p_X) = \mathbb{V}_S(p_S) \cdot \mathbb{V}_C(p_S)$ . Este é o desacoplamento que buscávamos.

## 4. Conclusão

Atualmente estamos trabalhando na caracterização de níveis intermediários de conhecimento do adversário, em que seu conhecimento é mais refinado do que uma *prior*, mas não tão refinado quanto o conhecimento completo do ambiente.

## Referências

- [Alvim et al. 2012] Alvim, M. S., Chatzikokolakis, K., Palamidessi, C., and Smith, G. (2012). Measuring information leakage using generalized gain functions. In *Proceedings of the IEEE Computer Security Foundations Symposium (CSF)*.
- [Chiasson and van Oorschot 2015] Chiasson, S. and van Oorschot, P. C. (2015). Quantifying the security advantage of password expiration policies. *Journal of Designs, Codes, and Cryptography*, 77(2-3):401–408.
- [Mardziel et al. 2014] Mardziel, P., Alvim, M. S., Hicks, M., and Clarkson, M. (2014). Quantifying information flow for dynamic secrets. In *Proceedings of the IEEE Symposium on Security and Privacy (Oakland)*.
- [McIver et al. 2014] McIver, A., Meinicke, L., and Morgan, C. (2014). Compositional closure for Bayes risk in probabilistic noninterference. In *Proc. ICALP’10*.
- [Zhang et al. 2010] Zhang, Y., Monrose, F., and Reiter, M. K. (2010). The security of modern password expiration: an algorithmic framework and empirical analysis. In *Proceedings of the ACM Conference on Computer and Communications Security (CCS)*.