

# Uma Análise Empírica de Interações em Redes Sociais

Fabrizio Benevenuto e Virgílio Almeida

<sup>1</sup>Departamento de Ciência da Computação  
Universidade Federal de Minas Gerais  
Belo Horizonte - Brasil

{fabricio,virgilio}@dcc.ufmg.br

**Resumo.** *Redes sociais online se tornaram extremamente populares e vêm causando o surgimento e a crescente popularização de uma nova onda de aplicações na Web. Com uma enorme quantidade de conteúdo criado a cada dia e por permitir o registro de diversos tipos de interações entre os usuários, redes sociais online se tornaram alvo de diversas áreas de pesquisa, não só relacionadas à computação, mas também áreas como a física, a sociologia, a economia, a psicologia e a comunicação. Apesar do grande interesse, pouco se sabe sobre o comportamento dos usuários e suas formas de interação em redes sociais online. Essa tese investiga as diferentes formas de interações em redes sociais, cobrindo aspectos do comportamento e da navegação dos usuários, bem como aspectos relacionados à postagem de conteúdo não solicitado. Para isso, coletamos dados de várias redes sociais atuais em larga escala. Nossas medições revelam padrões de comportamento e interação típicos, que variam de acordo com as mídias utilizadas para compartilhamento de conteúdo e interação. A partir dessas análises de comportamento, um método para a detecção de usuários maliciosos em redes sociais online é proposto.*

## 1. Introdução

Desde seu início a Internet tem sido o palco de uma série de novas aplicações, incluindo a WWW, aplicações par-a-par (P2P) e email. Hoje em dia a Web tem recebido uma nova onda de aplicações associadas ao crescimento e proliferação de redes sociais e mídia digital. Várias redes sociais surgiram, incluindo redes de profissionais (ex. LinkedIn), redes amizade (ex. MySpace, Facebook e Orkut), e redes voltadas para o compartilhamento de algum tipo específico de conteúdo como blogs (ex. LiveJournal), microblogs (ex. Twitter), fotos (ex. Flickr) e vídeos (ex. YouTube).

Redes sociais têm atraído milhões de usuários. De acordo com uma pesquisa recente da Nielsen Online [Nielsen Online 2009], mídia social passou na frente de email como a atividade online mais popular. Mais de dois terços da população online global visita ou participa de redes sociais ou blogs. Como comparação, se o Facebook fosse um país, seus 600 milhões de usuários registrados o colocariam como o terceiro país mais populoso do mundo [Facebook 2010]. Além da grande popularidade, redes sociais também possuem estatísticas impressionantes em termos de conteúdo gerado por usuários. Usuários do YouTube criam cerca de 10 horas de vídeos a cada minuto [YouTube 2010].

Apesar de tanta popularidade e da enorme quantidade de dados disponível nesses ambientes, o estudo de redes sociais ainda este em sua infância, já que novos problemas,

desafios e oportunidades de pesquisa vêm surgindo continuamente em diferentes áreas. Na computação, redes sociais vêm se tornando um tema chave em pesquisas em várias áreas, incluindo sistemas multimídia, recuperação de informação, mineração de dados e aprendizagem de máquina. Além disso, por oferecem registros de interações e laços de amizades existentes entre usuários, redes sociais permitem que questões de diferentes áreas possam ser quantificadas e abordadas em larga escala. É neste contexto que esta tese está inserida.

Essa tese investiga as diferentes formas de interações existentes em redes sociais online, cobrindo aspectos do comportamento e da navegação dos usuários, bem como aspectos relacionados à postagem de conteúdo não solicitado. Nossa metodologia consiste em coletar dados de redes sociais online em larga escala e caracterizar interações e aspectos do comportamento dos usuários, de forma a obter modelos que descrevem tais comportamentos. Finalmente, um mecanismo de detecção de usuários maliciosos que utiliza os padrões caracterizados é proposto.

As próximas seções deste resumo descrevem algumas contribuições realizadas nessa tese e sumariza as principais publicações científicas realizadas. Finalmente, a seção 6 discute o impacto dessas publicações.

## **2. Técnicas de coleta de redes sociais em larga escala**

No passado o estudo de redes sociais era um domínio de sociólogos e antropólogos, quando ferramentas típicas para obtenção de dados eram pesquisas e entrevistas [Wasserman et al. 1994]. Como consequência, muitos desses esforços foram realizados bases de dados pequenas e pouco representativas. Com o surgimento de redes sociais como Orkut e Facebook, surgiu a oportunidade de estudos sobre redes sociais com o uso de grandes bases de dados. Entretanto, a coleta e o processamento de grandes quantidades de dados de redes sociais muitas vezes requerem o uso de técnicas de introduzam o mínimo viés nos dados coletados. Muitas vezes, para seguirmos uma metodologia científica adequada precisamos coletar o grafo inteiro, o que envolve a coleta de grafos compostos por milhões de nodos e bilhões de arestas.

Existem diferentes estratégias para se coletar dados de redes sociais, que variam desde a construção de coletores distribuídos até mesmo à reconstrução de requisições que passam por um agregador de tráfego (ex. Proxy). Várias técnicas de coleta de redes sociais online foram empregadas ao longo dessa tese. O arcabouço construído foi utilizado em diversos artigos e vem sendo divulgado e compartilhado através de mini-cursos em importantes conferências brasileiras da área de computação como Webmedia'10, SBBD'10, IHC'10 e SBSC'10 [Benevenuto 2010], SBRC [Benevenuto et al. 2011b] e JAI [Benevenuto et al. 2011a].

## **3. Modelagem do Comportamento dos Usuários**

Com o objetivo de estudar como usuários se comportam quando eles se conectam em redes social nós coletamos dados que capturam cada clique realizado por usuários através de um agregador de tráfego. Nossas análises cobrem quatro sistemas: Orkut, MySpace, Hi5 e LinkedIn e provêem uma visão geral do tipo, duração, frequência e seqüência das atividades realizadas pelos usuários quando eles se conectam a esses sítios Web. Dentre as principais contribuições nesse tópico, podemos citar a modelagem

estatística do processo de chegada de requisições e sessões de usuários nessas redes sociais online. Além disso, nós propomos um modelo baseado em um grafo probabilístico para caracterizar a navegação do usuário de uma atividade para outra (ex. ver foto, postar mensagem, etc.) dentro de diferentes tipos de sessões. Nosso estudo revela várias características do comportamento dos usuários (ex. algumas atividades possuem grandes chances de serem repetidas) que possuem implicações para aspectos relacionados à interface e ao desempenho do sistema. O principal artigo [Benevenuto et al. 2009f] que cobre esses resultados obteve 58 citações de acordo com o Google scholar em um ano e meio (novembro de 2009 a maio de 2011).

#### **4. Caracterização das Interações entre Usuários**

Nosso trabalho detalha os diferentes tipos de interações existentes em redes sociais online e caracteriza o uso dessas interações pelos seus usuários. Vários trabalhos foram publicados neste tópico. Em particular, em [Benevenuto et al. 2009f] nós mostramos que 92% das interações dos usuários do Orkut são silenciosas, ou seja, em 92% dos casos os usuários acessaram algum conteúdo de outros usuários sem deixar nenhuma mensagem ou comentário. Curiosamente, cerca de 20% do conteúdo acessado não é conteúdo de amigos imediatos, sendo que a ferramenta de atualizações é a principal responsável por promover interações em usuários que não são imediatamente amigos. Nossos resultados ainda mostram que a maior parte das interações ocorrem em localizações geográficas próximas, o que possui diversas implicações abordagens de distribuição de conteúdo eficientes.

Outras formas de interação exploradas estão relacionadas às interações através de recursos multimídia, em especial vídeos. Vários serviços na Web 2.0 oferecem funções baseadas em vídeos como alternativas para funções que utilizam apenas texto, como revisões e opiniões sobre produtos e propagandas [Shannon 2007]. Sendo assim, nós caracterizamos diversas diferenças entre interações através textuais e interações que ocorrem unicamente através de vídeos. Nosso trabalho caracteriza interações assíncronas através de vídeos resposta no YouTube, revelando diversas diferenças nas interações dos usuários através desses recursos quando comparadas com interações textuais [Benevenuto et al. 2008a, Benevenuto et al. 2009e]. Características geográficas de interações através de vídeos foram exploradas em [Duarte et al. 2007]. Finalmente, em [Benevenuto et al. 2009a, Benevenuto et al. 2010b], foram propostos mecanismos para diferenciar tipos de usuários a partir de seus padrões de navegação em um servidor de vídeos.

#### **5. Identificação de Comportamento Malicioso e Oportunista**

A partir dos trabalhos de caracterização foram identificadas diversas formas de comportamentos e interações maliciosas. Sendo assim, nós investigamos mecanismos de detecção de usuários maliciosos a partir de padrões de seus comportamentos.

Inicialmente, abordamos o problema de usuários que postam vídeos spam no YouTube (ex. propaganda, pornografia). Após coletar vídeos e usuários do YouTube de forma apropriada, nós criamos uma grande coleção de usuários rotulados como maliciosos ou não maliciosos e identificamos características desses usuários capazes de distinguir essas duas classes [Benevenuto et al. 2008b, Benevenuto et al. 2008c]. Foram identificados

e caracterizadas 60 métricas com potencial discriminatório, extraídas de características do perfil do usuário no YouTube, de características de seus vídeos e da repercussão que eles tiveram e, finalmente, de características do usuário dentro do grafo social, como amizades recíprocas e amigos conectados entre si. A partir dessas análises criamos um algoritmo baseado em classificação hierárquica para a diferenciação automática de usuários maliciosos e não maliciosos [Benevenuto et al. 2009b, Benevenuto et al. 2009c]. A partir dos métodos propostos foi realizado um pedido de patente nos EUA, que está sob avaliação. Porém, uma patente provisória já foi concedida [Benevenuto et al. 2009d]. No artigo [Benevenuto et al. 2010c] nós sumarizamos os vários tipos de atividades maliciosas em redes sociais online, em especial redes voltadas para o compartilhamento de vídeos. Finalmente, seguindo uma estratégia semelhante à utilizada para a detecção de spam em vídeo, fomos capazes de identificar spam no Twitter [Benevenuto et al. 2010a].

## 6. Considerações Finais

Essa tese teve como base vários artigos completos publicados em conferências e revistas importantes, incluindo ACM TOMCCAP, ACM Multimedia, ACM SIGIR, ACM IMC, etc. Apesar de recentes, os trabalhos publicados ao longo dessa tese de doutorado somam mais de 300 citações de acordo com o Google scholar. Dois journals que estendem esses trabalhos estão submetidos e ainda em processo de avaliação (já em estado avançado). Além disso, a partir dos métodos propostos nessa tese para detecção de usuários maliciosos, foi realizado um pedido de patente nos EUA [Benevenuto et al. 2009d] que também está sob avaliação, porém já foi aceito como provisória. Alguns trabalhos publicados tiveram ampla repercussão na mídia, incluindo MTV, revista Info e o jornal “The New York Times” (<http://nyti.ms/9NU4fQ>).

Cabe ressaltar que essa tese de doutorado tem inspirado projetos de pesquisa [Almeida et al. 2011], além de artigos inseridos no contexto de iniciações científicas [Rodrigues et al. 2009, Rodrigues et al. 2010], dissertações de mestrado [Barbosa et al. 2011, Gomide et al. 2011, Gomide et al. 2011, Cunha et al. 2011] ou mesmo potenciais teses de doutorado [Figueiredo et al. 2011].

## Referências

- Almeida, J., Gonçalves, M., Prates, R., Hasan, D., Guimaraes, D., Oliveira, D., Belem, F., Figueiredo, F., Langbehn, H., Pinto, H., Lara, R., Ricci, S., and Benevenuto, F. (2011). Greenweb: Melhorando a qualidade da informação na web 2.0. In *Seminário Integrado de Software e Hardware (Semish)*.
- Barbosa, G., Santana, I., Gonçalves, G., Prates, R., Benevenuto, F., and Almeida, V. (2011). Characterizing interactions among members of deaf communities in orkut. In *IFIP Conference on Human-Computer Interaction (Interact)*.
- Benevenuto, F. (2010). Redes sociais online: Técnicas de coleta, abordagens de medição e desafios futuros. In *Tópicos em Sistemas Colaborativos, Interativos, Multimídia, Web e Banco de Dados*, chapter 2, pages 41–70. Sociedade Brasileira de Computação, Belo Horizonte, Brasil.
- Benevenuto, F., Almeida, J., and Silva, A. (2011a). Coleta e análise de grandes bases de dados de redes sociais online. In *Jornadas de Atualização em Informática (JAI)*.

- Benevenuto, F., Almeida, J., and Silva, A. (2011b). Explorando redes sociais online: Da coleta e análise de grandes bases de dados às aplicações. In *Mini-cursos do Simpósio Brasileiro de Redes de Computadores (SBRC)*.
- Benevenuto, F., Duarte, F., Rodrigues, T., Almeida, V., Almeida, J., and Ross, K. (2008a). Understanding video interactions in YouTube. In *ACM Conference on Multimedia (MM)*, pages 761–764.
- Benevenuto, F., Magno, G., Rodrigues, T., and Almeida, V. (2010a). Detecting spammers on twitter. In *7th Annual Collaboration, Electronic messaging, Anti-Abuse and Spam Conference (CEAS)*.
- Benevenuto, F., Pereira, A., Rodrigues, T., Almeida, V., Almeida, J., and Gonçalves, M. (2009a). Avaliação do perfil de acesso e navegação de usuários em ambientes web de compartilhamento de vídeos. In *Brazilian Symposium on Multimedia Systems and Web (WebMedia)*, pages 149–156.
- Benevenuto, F., Pereira, A., Rodrigues, T., Almeida, V., Almeida, J., and Gonçalves, M. (2010b). Characterization and analysis of user profiles in online video sharing systems. *Journal of Information and Data Management*, 1(2):115–129.
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., and Gonçalves, M. (2008b). Detectando usuários maliciosos em interações via vídeos no YouTube. In *Brazilian Symposium on Multimedia Systems and Web (WebMedia)*, pages 138–145.
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., and Gonçalves, M. (2009b). Detecting spammers and content promoters in online video social networks. In *IEEE Int'l conference on Computer Communications Workshops (INFOCOM)*, pages 337–338.
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., and Gonçalves, M. (2009c). Detecting spammers and content promoters in online video social networks. In *Int'l ACM Conference on Research and Development in Information Retrieval (SIGIR)*, pages 620–627.
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., and Gonçalves, M. (2009d). Methods for detecting spammers and content promoters in online video social networks. Patente Provisional USPTO application number 12/286,448. (Patente Provisional).
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., Gonçalves, M., and Ross, K. (2010c). Video pollution on the web. *First Monday*, 15(4).
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., and Ross, K. (2009e). Video interactions in online video social networks. *ACM Transactions on Multimedia Computing, Communications and Applications (TOMCCAP)*, 5(4):1–25.
- Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., Zhang, C., and Ross, K. (2008c). Identifying video spammers in online social networks. In *Workshop on Adversarial Information Retrieval on the Web (AIRWeb)*, pages 45–52.
- Benevenuto, F., Rodrigues, T., Cha, M., and Almeida, V. (2009f). Characterizing user behavior in online social networks. In *ACM SIGCOMM Internet Measurement Conference (IMC)*, pages 49–62.

- Cunha, E., Magno, G., Comarela, G., Almeida, V., Gonçalves, M., and Benevenuto, F. (2011). Analyzing the dynamic evolution of hashtags on twitter: a language-based approach. In *Int'l Workshop on Language in Social Media (LSM)*.
- Duarte, F., Benevenuto, F., Almeida, V., and Almeida, J. (2007). Geographical characterization of YouTube: a latin american view. In *Latin American Web Congress (LAWEB)*, pages 13–21.
- Facebook (2010). Facebook Press Room, Statistics. <http://www.facebook.com/press/info.php?statistics>. Acessado em Março/2010.
- Figueiredo, F., Benevenuto, F., and Almeida, J. (2011). The tube over time: Characterizing popularity growth of youtube videos. In *ACM Int'l Conference of Web Search and Data Mining (WSDM)*.
- Gomide, J., Veloso, A., Jr., W. M., Almeida, V., Benevenuto, F., Ferraz, F., and Teixeira, M. (2011). Dengue surveillance based on a computational model of spatio-temporal locality of twitter. In *ACM SIGWEB Web Science Conference (WebSci)*.
- Nielsen Online (2009). Social networks & blogs now 4th most popular online activity, 2009. <http://tinyurl.com/cfzjlt>. Acessado em Março/2010.
- Rodrigues, T., Benevenuto, F., Almeida, V., Almeida, J., and Gonçalves, M. (2009). Uma análise contextual de conteúdo duplicado no YouTube. In *Brazilian Symposium on Multimedia Systems and Web (WebMedia)*, pages 141–148.
- Rodrigues, T., Benevenuto, F., Almeida, V., Almeida, J., and Gonçalves, M. (2010). Equal but different: A contextual analysis of duplicated videos on youtube. *Journal of the Brazilian Computer Society*, 16(3):201–214.
- Shannon, M. (2007). Shaking hands, kissing babies, and...blogging? *Communications of the ACM*, 50(9):21–24.
- Wasserman, S., Faust, K., and Iacobucci, D. (1994). *Social Network Analysis: Methods and Applications (Structural Analysis in the Social Sciences)*. Cambridge University Press.
- YouTube (2010). YouTube fact sheet. [http://www.youtube.com/t/fact\\_sheet](http://www.youtube.com/t/fact_sheet). Acessado em Março/2010.