

Sigam-me os bons! Transformando robôs em pessoas influentes no Twitter

Johnnatan Messias¹, Lucas Schmidt¹,
Ricardo Oliveira¹, Fabricio Benevenuto¹

¹Departamento de Computação – Universidade Federal de Ouro Preto (UFOP)
CEP 35400-000 – Ouro Preto – MG – Brasil

Abstract. *Systems that classify influential users in social networks has been used with great frequency, being referenced in scientific papers and the media as the ideal standard for evaluation of influence in the social network Twitter. We consider this measure a complex and subjective and therefore suspect vulnerability and ease of handling these systems. Based on this, we performed experiments and analyzes in two ranking systems of influence: Klout and Twitalyzer. We create simple robots capable of interacting through Twitter accounts and measure their influence. Our results show that it is possible to be influential through simple strategies. This suggests that the systems do not have ideal metric to rank influence.*

Resumo. *Sistemas que classificam usuários influentes nas redes sociais tem sido usados com grande frequência, sendo referenciados em artigos científicos e na mídia como padrão ideal para avaliação de influência na rede social Twitter. Consideramos esta medição algo complexo e subjetivo e por isso suspeitamos da vulnerabilidade e facilidade de manipulação nesses sistemas. Baseado nisso, realizamos experimentos e análises em dois sistemas de classificação de influência: Klout e Twitalyzer. Criamos robôs simples capazes de interagir, através de contas no Twitter e medimos suas influências. Nossos resultados mostram que é possível ser influente através de estratégias simples. Isso sugere que os sistemas não possuem métricas ideais para classificar influência.*

1. Introdução

As redes sociais têm adquirido bastante destaque e crescente importância na sociedade moderna. Dentre elas, o *Twitter* tem conquistado grande quantidade de adeptos. É uma das redes sociais que mais movimentam usuários e uma das que mais geram troca de informações. Em sistemas como o *Twitter*, usuários podem influenciar e serem influenciados por outros, o que tem atraído grande interesse político e de empresas relacionadas ao *marketing*.

Neste contexto, várias empresas tem se especializado em medir influência no *Twitter* e em outras redes sociais. Dentre os sistemas mais populares estão o *Klout*[Klout 2012] e o *Twitalyzer*[Twitalyzer 2012], que utilizam abordagens de medições de influência simples e cujos detalhes não são revelados ao público.

Surpreendentemente, vários jornais, revistas e até mesmo artigos científicos [H. Purohit and Sheth 2011, Anger and Kittl 2011, Brown and Feng 2011, Yan and Kaziunas 2012] tem utilizado essas ferramentas, e divulgado *rankings* de

usuários influentes. Como exemplo, uma matéria do jornal *The New York Times* apresentou um estudo das pessoas mais influentes do mundo, baseado no *Twitalyzer* [Leonhardt 2011]. Entre os mais influentes, o estudo indicou o humorista brasileiro Rafinha Bastos, o *rapper* americano Snoop Dogg, o presidente dos Estados Unidos Barack Obama e o apresentador brasileiro Luciano Huck.

Baseado nisso, queremos investigar que estratégias podem tornar usuários comuns em usuários influentes, segundo *rankings* do *Klout* e *Twitalyzer*. Criamos algoritmos robôs simples capazes de interagir, através de contas no *Twitter*, como se fossem usuários na rede, trocando informações, seguindo e conquistando novos seguidores, durante um período de 90 dias. Os resultados das análises nos mostraram que as ferramentas *Klout* e *Twitalyzer* não apresentaram métricas ideais para classificar a influência de um indivíduo na rede. Constatamos que *spammers* espalhados na rede podem facilmente se passar por celebridades e pessoas populares, com um alto nível de influência baseado no *Klout Score* e *Twitalyzer Impact*.

Este artigo encontra-se organizado da seguinte forma: na seção 2 apresentamos os trabalhos relacionados com o tema deste artigo. Na seção 3 apresentamos os algoritmos dos robôs utilizados para interagir na rede social e na seção 4 mostramos os cenários de experimentos. Já na seção 5 apresentamos a forma de coleta de dados e *log* da execução do *bot*. Na seção 6 apresentamos os resultados obtidos. Por fim, apresentamos os trabalhos futuros na seção 7 e as conclusões do artigo na seção 8.

2. Trabalhos relacionados

A classificação da influência de um usuário no *Twitter* se torna uma tarefa longa e complexa. Longa porque é uma análise que deve ser considerada desde a criação do *Twitter*. E complexa porque não há um consenso exato do que é influência e de como mensurá-la. Alguns estudos apontam que um número enorme de seguidores de um usuário no *Twitter* é suficiente para determinar o seu grau de relevância. Outros estudos indicam que a influência de uma pessoa no *Twitter* está muito mais ligada ao conteúdo que ela compartilha do que com o número de pessoas que a seguem. Com isso, houveram várias tentativas e métodos para medir, de forma adequada, a influência dos usuários no *Twitter* [Cha et al. 2010, Bakshy et al. 2011, Lee et al. 2010, Romero et al. 2011]. No trabalho de [Weng et al. 2010] é proposto o *TwitterRank*, um algoritmo baseado no *PageRank*, que usa tanto o grafo de conexões do *Twitter* quanto informações de *tweets* publicados para identificar usuários influentes. Por outro lado [Pal and Counts 2011] usou agrupamento e classificação de mais de 15 características extraídas do grafo do *Twitter* e dos *tweets* postados por usuários para identificar os mais influentes.

No artigo de [Saptarshi Ghosh and Gummadi 2012], de forma pioneira, foi investigado a atividade de *link farms* no *Twitter* e proposto formas para dissuadir tal atividade. Os autores constataram que um pequeno grupo de usuários legítimos, populares e ativos no *Twitter* são responsáveis pela maioria dos *link farms*. Eles buscam acumular capital social seguindo diversos usuários e conquistando novos seguidores. Com isso, *spammers* exploram este tipo de comportamento para conquistar seguidores e reputação no *Twitter*. Como forma de minimizar a influência deste tipo de comportamento, os autores propuseram um esquema de classificação, conhecido como *Collusionrank*, onde os usuários são penalizados por seguir *spammers*, reduzindo a influência de *spammers* e seus seguidores.

[Zhang and Paxson 2011] propuseram uma abordagem para identificar atividades automáticas no *Twitter* e mostrou que 16% das contas ativas no *Twitter* exibem um alto grau de automação. Finalmente, [Castillo et al. 2011] abordou o problema de fornecimento de métodos automáticos para avaliar a credibilidade de um determinado conjunto de *tweets*, classificando os *tweets* como com credibilidade e sem credibilidade.

3. Construção dos bots

Antes de explicar o funcionamento dos *bots*, primeiramente vamos apresentá-los. Foram criados dois algoritmos robôs, usando a *API Python* do *Twitter*. O primeiro *bot*, denominado **fepessoinha** (<https://twitter.com/fepessoinhas2>) apenas segue automaticamente outros usuários e conquista novos seguidores. Para seguir os usuários, utilizamos o método de busca em largura, ou seja, a partir de um usuário inicial aleatório o algoritmo o inclui em uma lista, seguindo-o e selecionando aleatoriamente 30 usuários de sua lista de seguidos, que também são incluídos na lista. Feito isso, o processo será repetido de modo a seguir o próximo usuário, até o *bot* alcançar o limite de 2000 usuários seguidos, que é um limite imposto pelo *Twitter*. A Figura 1 mostra uma foto do perfil do *bot fepessoinha*¹.



Figura 1. Perfil bot fepessoinha - Twitter

O segundo, denominado **scarina** (<https://twitter.com/scarina91>), é capaz de interagir, como se fosse um usuário na rede, trocando informações, seguindo e conquistando novos seguidores. Para seguir os usuários, este *bot* utiliza do mesmo princípio utilizado pelo *bot fepessoinha*, também conquistando consequentemente novos seguidores. Porém, este possui duas diferenças: (1) após seguir os 2000 usuários o algoritmo exclui os usuários que não seguem o *bot* e (2) é capaz de postar *tweets*. Para isso, uma sequência do algoritmo lê um dicionário de palavras relacionadas ao tema "Rede Globo". Colocamos no dicionário as seguintes palavras: rede, programação, xuxa, novela, filme, audiência, melhor, reportagem, jornalismo, jornal, nacional, huck, angélica, willian, bonner, bernardes, malhação, notícia, destaques, bbb. Assim, o algoritmo prossegue solicitando uma busca no *Twitter* através do trecho "Globo + palavra", sendo a palavra uma das selecionadas aleatoriamente no dicionário. Em seguida, capta quatro dos *tweets* retornados na pesquisa e os posta em um intervalo de tempo aleatório. Conforme as postagens aumentam, as atividades e interações entre os usuários com o *bot scarina* também aumentam. A Figura 2 mostra uma foto do perfil do *bot scarina*¹.

Para conseguir automatizar os *bots*, de forma a respeitar as regras impostas pela API do *Twitter*. Os *bots* respeitam as seguintes restrições:

- Número máximo de requisições por hora = 350;
- Cada usuário pode seguir no máximo 2000 usuários, via API;
- Um usuário não pode seguir mais de 1000 usuários por dia.

¹ As fotos utilizadas no perfil de ambos os *bots* são fotos de conhecidas dos autores e que autorizaram o uso de suas fotos nos *bots*.



Figura 2. Perfil bot scarina - Twitter

4. Experimentos com os bots

Para analisar como os *bots* criados adquirem influência segundo o *Klout* e *Twitalyzer*, foram criados quatro cenários experimentais de forma a testar a vulnerabilidade e facilidade de manipulação dos classificadores de influência.

4.1. Cenário 1: Seguindo usuários (*Bot fepessoinha*)

O bot *fepessoinha* seguiu o limite máximo de usuários permitido pelo *Twitter* (2000), via API, na tentativa de obter seguidores.

4.2. Cenário 2: Seguindo e excluindo usuários (*Bot scarina*)

O bot *scarina* também seguiu o limite máximo de usuários permitido pelo *Twitter* (2000), via API. Posteriormente, o algoritmo do bot exclui alguns usuários, mantendo apenas os que também a seguiram. Neste cenário, o método utilizado para seguir usuários é o mesmo apresentado no cenário 1, porém exclui posteriormente os usuários que não seguem o bot.

4.3. Cenário 3: Seguindo, excluindo usuários e postando tweets (*Bot scarina*)

O bot *scarina* posta tweets de forma automática, após realizar a estratégia do **Cenário 2**. Tal cenário permite verificar o impacto nos *rankings* de influência devido à postagem de conteúdo. Para isso utilizou um dicionário de dados para postagens de temas relevantes. Conforme as postagens aumentam, as atividades e interações entre os usuários com o bot *scarina* também aumentam.

4.4. Cenário 4: Seguindo, excluindo usuários, postando tweets e com interrupções na execução (*Bot scarina*)

O bot *scarina* segue e ganha novos seguidores além de postar tweets utilizando também o dicionário de dados. Neste cenário também verificamos e analisamos algumas interrupções e reinícios na execução do algoritmo do bot. Com o intuito de analisar o que acontece com a influência do bot quando este fica períodos de tempo inativo.

5. Coleta de dados

Para coletar os dados pertinentes para este artigo, na criação dos bots *scarina* e *fepessoinha* configuramos suas contas do *Twitter* a fim de enviar todas as informações aos e-mails cadastrados. Assim, teríamos um log de todas as ações, informações e atividades realizadas durante o período de 90 dias de experimento. Posteriormente, fizemos um algoritmo *parser* para coletar os e-mails, em arquivos ".eml", do servidor do *Yahoo*

(serviço de *e-mail* das contas). Com isso, durante os 90 dias, conseguimos obter as seguintes informações do *Twitter*: *tweets* favoritos, *tweets* mencionados, mensagens, *tweets* respondidos, *retweets* e usuários seguidores.

Após o processo de execução, acessamos os sites do *Klout* e *Twitalyzer* para coletar os resultados de todas as interações. No site da *Klout* foi possível coletar os resultados dos 90 dias de experimento, através de gráficos. Já no site da *Twitalyzer*, apenas conseguimos um resultado da influência final para cada usuário, desde o dia de sua criação. Não conseguimos dados dos dias anteriores ao de consulta.

Os dados coletados através dos *e-mails* servem para complementar os resultados obtidos pelos sistemas *Klout* e *Twitalyzer* e com isso achamos conveniente mostrar os resultados finais, para comprovar a vulnerabilidade e fácil manipulação dos sistemas *Klout* e *Twitalyzer*.

6. Resultados

Para se chegar ao *Klout Score*, o *Klout* trabalha com mais de 25 variáveis divididas em 3 grupos: *Network Impact* (Influência na rede), *Amplification Probability* (Probabilidade de amplificação) e *True Reach* (Alcance Verdadeiro). O *Klout Score* vai de 0 à 100, e, teoricamente, é o resultado final do grau de influência de um usuário. No caso do *Twitalyzer*, este possui o número conhecido como *Twitalyzer Impact*. Este número também vai de 0 à 100 e baseia-se em 15 variáveis para se chegar ao valor final.

6.1. Cenário 1

O gráfico correspondente à Figura 3 mostra detalhadamente a quantidade de seguidores que o *bot fepessoinha* conquistou, resultando ao final do experimento o total de 417 seguidores. A quantidade de seguidores foi mais alta no momento em que o *bot fepessoinha* executou o processo de seguir os 2000 usuários (durante os primeiros 9 dias).




Figura 3. (a) Gráfico de Seguidores do bot fepessoinha (b) Gráfico do acumulativo de seguidores do bot fepessoinha

Com isso, podemos ver no gráfico correspondente à Figura 4, o resultado do *Klout Score* do *bot fepessoinha*. O *Klout Score* mostra o resultado final da influência de um usuário. É possível ver que nos 2 primeiros dias há uma grande crescente, devido aos novos usuários que passaram a seguir o *bot*, alcançando o valor 18 de *Klout Score*. Ao fim da execução do algoritmo do *bot* (após 9 dias) é possível ver uma queda constante do *Klout Score* até alcançar o valor 12,3 ao fim dos 90 dias de experimento.

Já no *Twitalyzer*, o *bot* conseguiu o valor 9, durante os 90 dias de experimento.




Figura 4. Resultados Klout Score do bot fepessoinha

Além desses resultados, o bot *fepessoinha* obteve durante os 90 dias de experimento: 0 *tweets* favoritos e 0 *retweets*, devido ao fato de ter publicado apenas 7 *tweets*. Desses 7, apenas 4 *tweets* foram respondidos. Conforme é mostrado na Figura 5 o bot obteve um valor considerável de *tweets* mencionados e mensagens recebidas resultando ao fim do experimento o total de 24 e 21 respectivamente. Observamos que grande parte das menções e mensagens foram feitas nos 9 primeiros dias, nos dias em que o algoritmo de coleta de usuários do bot estava em execução. A maioria das menções e mensagens foram de questionamentos sobre quem era o bot *fepessoinha*, e de onde os usuários se conheciam. Um questionamento comum entre usuários que iniciam um relacionamento em uma rede social.




Figura 5. (a) Gráfico de Tweets mencionados do bot fepessoinha (b) Gráfico de mensagens do bot fepessoinha

6.2. Cenário 2

O gráfico correspondente à Figura 6 é o que expressa melhor o resultado deste experimento. Fazendo uma comparação com o bot *fepessoinha*, o bot *scarina* alcançou valores menores de influência. É possível ver que o fato do algoritmo do bot *scarina* excluir os usuários que não o seguem, sua influência acaba sendo menor do que o bot *fepessoinha*, que não exclui usuários, durante os 9 dias em que o algoritmo de coleta e exclusão de usuários foi executado. Após os 9 dias, ao fim do primeiro processo de coleta e ex-

clusão de usuários, é iniciado o processo de postagem de *tweets*, iniciando o processo do **Cenário 3**.




Figura 6. Comparativo do Klout Score entre os bots scarina e fepessoinha

6.3. Cenário 3

A partir do 10º dia, apresentado pelo gráfico correspondente à Figura 6, podemos ver o início de uma discrepância brusca entre os *bots scarina* e *fepessoinha*. O *bot scarina*, inicia a publicação de *tweets* a partir do 10º dia, e no 17º dia já atinge o valor 41,8 de *Klout Score*. Observamos no *bot scarina*, através do **Cenário 3**, que o *bot* passa a conquistar novos seguidores mesmo sem seguir outros usuários, apenas pela relevância do conteúdo que posta. O conteúdo que o *bot* posta acaba sendo de interesse de outros usuários que consequentemente passam a seguir o *bot*. Com isso, é possível ver que apenas seguir usuários, como realizado no **Cenário 1**, não é suficiente para atingir um alto grau de influência. Logo, o sistema *Klout*, considera também as publicações de um usuário, para elevar o nível de influência. Enfim, o *bot scarina* chegou ao valor máximo de 41,8 no *Klout*, enquanto o *bot fepessoinha* alcançou o valor máximo de 18 no *Klout*.

Além do valor do *Klout*, o *bot scarina* conseguiu o valor 86 no *Twitalyzer*. Uma comparação precisa, dos níveis de influência mais altos, pode ser verificada no gráfico correspondente à Figura 7.




Figura 7. Comparativo Klout e Twitalyzer - fepessoinha x scarina

6.4. Cenário 4

Os resultados para o **Cenário 4** podem ser vistos claramente no gráfico correspondente à Figura 8. É possível ver grandes vales e picos que correspondem à interrupções na execução do algoritmo de postagem de *tweets*. Foram duas interrupções. A primeira interrupção se deu no 46º dia. Mantivemos o algoritmo de postagem de *tweets* desativado por 6 dias. Reiniciamos o processo completo do *bot* (coleta/exclusão de usuários e postagem) e mantivemos por mais 6 dias a execução, até realizarmos uma nova interrupção. Reiniciamos então apenas o processo de postagem de *tweets*. Através do gráfico, fica evidente que a não publicação de *tweets* (com a interrupção do processo) diminuiu bruscamente o grau de influência do *bot*, baseado no *Klout Score*.




Figura 8. Resultados Klout Score do bot scarina

Conseguimos ver o mesmo comportamento nos gráficos que correspondem aos seguidores, menções e mensagens, principalmente após a primeira interrupção. No gráfico correspondente à Figura 9 podemos ver, a partir do dia 46 que o *bot* conquista diversos novos seguidores, por executar todo o processo inicial, após a primeira interrupção. Ao final de 90 dias de experimento o *bot* conquistou o total de 691 seguidores.




Figura 9. (a) Gráfico de Seguidores do bot scarina (b) Gráfico do acumulativo de seguidores do bot scarina

No gráfico correspondente à Figura 10 também podemos ver, a partir do dia 46 que o *bot* recebe novas menções e mensagens. Como o processo inicial foi executado novamente, conquistando novos seguidores, a maioria das menções e mensagens foram

de questionamentos sobre quem era o *bot scarina*, e de onde os usuários se conheciam. Ao final de 90 dias de experimento o *bot scarina* obteve 52 menções e 45 mensagens.




Figura 10. (a) Gráfico de Tweets mencionados do bot scarina (b) Gráfico de mensagens do bot scarina

Além dos resultados já apresentados, o *bot scarina* postou 4997 *tweets*, durante os 90 dias de experimento. Deste total, tivemos apenas 6 *tweets* entre os favoritos pelos usuários seguidores. Além disso, obteve ao fim dos 90 dias de experimento o total de 94 *retweets* e 109 *tweets* respondidos.

6.5. Resultados finais

No final dos 90 dias de experimento, coletamos os valores de *Klout* e *Twitalyzer* das contas mais influentes do *Twitter* e fizemos uma comparação final com os bots *fepessoinha* e *scarina*, conforme é mostrado no gráfico correspondente à Figura 11. Entre os mais influentes, estão o humorista brasileiro Rafinha Bastos, o *rapper* americano Snoop Dogg, o presidente dos Estados Unidos Barack Obama e o apresentador brasileiro Luciano Huck. Além disso, incluímos nesta comparação os *twitters* dos professores e pesquisadores Lada Adamic (*keynote speaker* do ICWSM e do *Web Science*) e Virgílio Almeida (Pesquisador A1 do CNPq, atualmente secretário do ministro de ciência e tecnologia), influentes na área de análise de redes sociais. Podemos ver que mesmo de forma automatizada, os bots alcançaram níveis iguais ou acima, de outras pessoas com alta reputação, nos classificadores de influência *Klout* e *Twitalyzer*.




Figura 11. Comparação Klout e Twitalyzer - os mais influentes

7. Trabalhos Futuros

Com a apresentação e comparação de algumas estratégias utilizadas por *bots* na rede social *Twitter*, este trabalho servirá como base para o estudo e comparação de outras estratégias de influencias nas redes sociais. Um incremento interessante seria utilizar o *bot scarina* com o dicionário de dados baseado nos *trends topics* do próprio *Twitter*, de forma dinâmica. Outra alternativa, seria utilizar estratégias de PLN (Processamento de Linguagem Natural) visando a geração e compreensão automática de línguas humanas naturais, no tratamento dos *tweets* postados pelos usuários. Com isso, o *bot* seria capaz de interagir, de forma automática postando conteúdos relacionados ao contexto em que for inserido. Enfim, avaliar mais detalhadamente as melhores estratégias que os *bots* podem usar para manipular *rankings* de influencias em redes sociais.

8. Conclusões

Neste artigo criamos robôs simples capazes de interagir, através de contas no *Twitter*, como se fossem usuários na rede, trocando informações, seguindo e conquistando novos seguidores, durante o período de 90 dias. Constatamos que durante este período, os *bots* conseguiram resultados significantes em sistemas de classificadores de influência como *Klout* e *Twitalyzer*.

Artigos científicos e a mídia em geral têm usado esses sistemas, exageradamente, como padrão para avaliar a influência de um usuário nas redes sociais. Ao decorrer do trabalho, conseguimos constatar que suas métricas são vulneráveis e facilmente manipuláveis quando utilizamos contas automatizadas, conhecidas como *bots*. Com isso, mostramos que simples robôs no *Twitter* podem conseguir altos níveis de influência, segundo as métricas do *Klout* e *Twitalyzer*, confirmando nossa hipótese. Além disso, verificamos de forma experimental e prática algumas estratégias para os *bots*. A estratégia de apenas seguir usuários e ser seguido por outros usuários não é o suficiente para um alto grau de influência. Como melhor estratégia, verificamos que o *bot* também deve interagir postando conteúdos relevantes na rede.

Baseado nos resultados que obtivemos, podemos dizer que *spammers* espalhados na rede podem facilmente se passar por celebridades e pessoas populares apenas utilizando contas automatizadas.

Finalmente, ao fim do experimento, para comprovar a eficácia dos nossos algoritmos, em um curto período, nossos *bots* conquistaram níveis próximos à níveis de personalidades e pessoas com alta reputação, que são consideradas as mais influentes no *Twitter*. Com isso, mostramos que processos automáticos com *bots* podem conquistar altos níveis de influência.

Referências

- Anger, I. and Kittl, C. (2011). Measuring influence on twitter. In *I-KNOW*, page 31.
- Bakshy, E., Hofman, J. M., Mason, W. A., and Watts, D. J. (2011). Everyone's an influencer: quantifying influence on Twitter. In *ACM WSDM*, pages 65–74.
- Brown, P. and Feng, J. (2011). Measuring user influence on twitter using modified k-shell decomposition. In *The Social Mobile Web*.

- Castillo, C., Mendoza, M., and Poblete, B. (2011). Information credibility on Twitter. In *ACM Int'l conference on World Wide Web (WWW)*, pages 675–684.
- Cha, M., Haddadi, H., Benevenuto, F., and Gummadi, K. P. (2010). Measuring User Influence in Twitter: The Million Follower Fallacy. In *AAAI ICWSM*.
- H. Purohit, Y. Ruan, A. J. S. P. and Sheth, A. (2011). Understanding user-community engagement by multi-faceted features: A case study on twitter. In *Conference of Social Media Analytics Workshop at World Wide Web (WWW)*.
- Klout (2012). <http://www.klout.com>.
- Lee, C., Kwak, H., Park, H., and Moon, S. (2010). Finding influentials based on the temporal order of information adoption in Twitter. In *ACM WWW*.
- Leonhardt, D. (2011). A better way to measure twitter influence. *The New York Times*.
- Pal, A. and Counts, S. (2011). Identifying topical authorities in microblogs. In *ACM WSDM*, pages 45–54.
- Romero, D. M., Galuba, W., Asur, S., and Huberman, B. A. (2011). Influence and passivity in social media. In *ACM WWW*, pages 113–114.
- Saptarshi Ghosh, Bimal Viswanath, F. K. N. K. S. K. G. F. B. N. G. and Gummadi, K. (2012). Understanding and Combating Link Farming in the Twitter Social Network. In *Proceedings of the 21st International World Wide Web Conference (WWW'12)*, Lyon, France.
- Twitalyzer (2012). <http://www.twitalyzer.com/>.
- Weng, J., Lim, E.-P., Jiang, J., and He, Q. (2010). TwitterRank: finding topic-sensitive influential twitterers. In *ACM WSDM*.
- Yan, J. L. S. and Kaziunas, E. (2012). What is a tweet worth?: measuring the value of social media for an academic institution. In *Proceedings of the 2012 iConference, iConference '12*, pages 565–566, New York, NY, USA. ACM.
- Zhang, C. M. and Paxson, V. (2011). Detecting and Analyzing Automated Activity on Twitter. In *Passive and Active Measurement (PAM)*.