

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM
PSIQUIATRIA E CIÊNCIAS DO COMPORTAMENTO



TESE DE DOUTORADO

**Avaliação de mídias sociais como preditoras de episódios depressivos no
Transtorno Bipolar e promotoras de saúde mental na internet**

THAÍS CUNHA MARTINI

Orientadora Profa. Dra. MARCIA KAUER SANT'ANNA

Co-orientador: Prof. Dr. CHRISTIAN COSTA KIELING

Porto Alegre, maio de 2018

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM
PSIQUIATRIA E CIÊNCIAS DO COMPORTAMENTO



TESE DE DOUTORADO

**Avaliação de mídias sociais como preditoras de episódios depressivos no
Transtorno Bipolar e promotoras de saúde mental na internet**

THAÍS CUNHA MARTINI

Orientadora Profa. Dra. **MARCIA KAUER SANT'ANNA**

Co-orientador: Prof. Dr. **CHRISTIAN COSTA KIELING**

Porto Alegre, Brasil.

2018

CIP - Catalogação na Publicação

Martini, Thaís Cunha

Avaliação de mídias sociais como preditoras de episódios depressivos no Transtorno Bipolar e promotoras de saúde mental na internet / Thaís Cunha Martini. -- 2018.

94 f.

Orientadora: Marcia Kauer-Sant'Anna.

Coorientador: Christian Costa Kieling.

Tese (Doutorado) -- Universidade Federal do Rio Grande do Sul, Faculdade de Medicina, Programa de Pós-Graduação em Psiquiatria e Ciências do Comportamento, Porto Alegre, BR-RS, 2018.

1. transtorno bipolar. 2. mídias sociais. 3. promoção de saúde mental on-line. 4. fenótipo digital. 5. Facebook. I. Kauer-Sant'Anna, Marcia, orient. II. Kieling, Christian Costa, coorient. III. Título.

AGRADECIMENTOS

Agradeço à Profa. Marcia Kauer Sant`Anna que desde o dia 0 estive ao meu lado, pelas incontáveis reuniões despretensiosas, cheias de ideias, que nos trouxeram até aqui. Ao seu esforço contínuo em ajudar quem acredita ter potencial. Obrigada, de coração.

Ao prof. Christian Kieling, agradeço pelas oportunidades e excelência de ensino. Ao prof. Olavo Amaral, pelas contribuições no projeto e execução. Ao prof. Ives pela incansável ajuda nas análises.

Ao jovem Diego Rabelo, que aceita desafios e missões das mais improváveis. Aos colegas que foram a força motriz para manter o barco navegando durante o tempo de entrevistas e recrutamento de pacientes e controles e, principalmente, enquanto estive na Austrália, agradeço aos valentes Mathias, Daniel, Daiane, Flavia, Letícia e Joana B. Agradeço a todos os colegas de Laboratório de Psiquiatria Molecular que contribuíram de alguma forma com este trabalho: Gabi B, Keila, Jairo, Erico, Pedro Goi, Silvia.

I am thankful for the opportunity Michael and Lesley Berk gave to me, for the inspirational months beside excellent investigators as the young Emma and the experient Olivia. I am also thankful for those who I met at Kitchener House, responsible for happy days as a big Family in great Geelong/ Australia.

À família que apoiou e puxou a orelha nas horas certas, Maria e Maura. Ao meu irmão Pedro Henrique pelo apoio e risadas; à minha irmã Christiane que sempre foi base e espelho, obrigada também ao pequeno Paulo, que nos faz cantar e dizer “não” todos os dias (enfim aprendemos).

Ao essencial suporte do meu pai, Pedro Martini, que apoiou incondicionalmente cada fase de todo processo acadêmico, que acordava de madrugada para falar pelo Skype todos os dias (e que foi inclusive a única voz que ouvi por um bom tempo).

Ao meu amor Bruno, que enfrentou com carinho e paciência a distância e as confusões da vida de uma pós-graduanda.

SUMÁRIO

Abreviaturas e siglas	3
Lista de tabelas	4
Lista de figuras	5
RESUMO	6
ABSTRACT	8
1. APRESENTAÇÃO	9
2. INTRODUÇÃO	10
3. REVISÃO DA LITERATURA	12
3.1. Transtorno bipolar	12
3.1.1. Psicoeducação e Transtorno Bipolar	12
3.1.2. Alterações cognitivas e funcionais no transtorno bipolar	13
3.2. Fenótipo digital e seu papel na saúde mental	15
3.3. Mídias sociais e promoção de saúde mental	19
3.3.1. Estudo do caso do BuzzFeed	20
3.3.2. Análise de métricas e conteúdo em redes sociais	21
3.4. Mídias sociais e preditores clínicos de depressão	24
3.4.1. Análise de conteúdo semântico	25
4. JUSTIFICATIVA	27
4.1. Justificativa para o artigo 1	27
4.2. Justificativa para o artigo 2	28
4.3. Hipóteses	28
4.4. Objetivos	29
4.4.1. Artigo 1	29
4.4.2. Artigo 2	29
5. ARTIGO 1	30
6. ARTIGO 2	58
7. CONCLUSÕES E CONSIDERAÇÕES FINAIS	75
8. REFERÊNCIAS BIBLIOGRÁFICAS	80
9. ANEXOS	85

Abreviaturas e siglas

TB – Transtorno Bipolar

SNS – Social Network Sites/ Site de redes sociais *on-line*/ mídias sociais

FB – Facebook

SSM – Semana de Saúde Mental do BuzzFeed

BFMHW - *BuzzFeed Mental Health Week*

LIWC - *Linguistic Inquiry Word Count*

Lista de tabelas

Tabela 1 - Métricas de avaliação de posts em mídias sociais

23

Lista de figuras

- Figura 1.** A fenotipagem digital envolve a coleta de dados através de sensores, teclado e voz/ fala de smartphones para medir o comportamento, a cognição e o humor. 15
- Figura 2.** A fotografia à direita tem um matiz mais alto (mais azul), uma saturação mais baixa (mais cinza) e um brilho mais baixo (mais escuro) do que a fotografia à esquerda. Fotos do Instagram postadas por indivíduos deprimidos pontuaram mais alto para as características das fotos como a da direita, em comparação com fotos postadas por indivíduos saudáveis. 17
- Figura 3.** Postagem em português da campanha internacional da Semana de Saúde Mental do BuzzFeed. 20
- Figura 4.** Funil de marketing adaptado para métricas de mídia social e promoção da saúde mental – O funil representa as cinco etapas do ciclo de vendas: exposição, influência, engajamento (consciência de marca), ação / conversão e retenção de clientes (geração de leads) e a etapa final é a retenção de clientes. 22

RESUMO

Os sintomas do transtorno bipolar (TB) envolvem alterações no humor, na cognição e no comportamento, o que também é relacionado a um importante prejuízo cognitivo social do paciente, tornando-o menos engajado socialmente. As mídias sociais são ferramentas importantes tanto para a promoção de saúde mental na internet quanto para avaliação de pacientes. No entanto, muito pouco ainda se sabe com relação ao seu real efeito na prática clínica. Estas mídias podem ser úteis para a área de pesquisa e para a clínica através da observação desta forma de expressão do paciente como um todo, pois o mundo virtual faz cada vez mais parte da rotina de muitas pessoas. Neste trabalho, avaliamos como os recursos de mídias sociais podem ser utilizados como preditores clínicos de depressão no TB e também como promotores de saúde mental na internet. No primeiro artigo deste trabalho, escolhemos estudar a Semana de Saúde Mental do BuzzFeed (BFMHW) pois, em dezembro de 2015, BuzzFeed promoveu a Semana de Saúde Mental (BuzzFeed, on-line, 2017). Utilizamos métricas de mídias sociais para medir o impacto do conteúdo: exposição, influência e engajamento. No total, foram 44 vídeos e posts analisados. De forma geral, a análise sugere que quanto maior o número de plataformas de mídias sociais alcançadas por um post, maiores as taxas de visualização. No segundo artigo e principal deste trabalho utilizamos recursos psicolinguísticos e dados de uso do Facebook extraídos das mídias sociais de pacientes com TB. O Linguistic Inquiry Word Count (LIWC) foi analisado com *machine learning*. Verificamos se as métricas de uso do Facebook ou a análise do conteúdo semântico de pessoas com TB poderiam prever o estado de humor avaliado através de escala clínica retrospectiva validada (NIMH Life Chart). O principal achado do segundo artigo mostra que o vocabulário LIWC pode indicar apenas uma tendência preditiva da depressão bipolar quando associada à variáveis conhecidas na literatura pela característica clássica preditiva, tais como idade, sexo e anos de estudo (AUC 86.7%). Uma vez retiradas estas variáveis, o valor preditivo perde a força (AUC 53.5%). O volume de uso do FB (atualização de status, postagens de fotos, curtidas e compartilhamentos) também apontou apenas uma tendência para predição da depressão bipolar (AUC 60%). Este resultado mostra que tanto o LIWC quanto os dados de uso do FB são recursos importantes para

direcionar tendências preditivas para depressão bipolar através do uso da internet. Estes resultados podem fornecer evidências de que o uso de mídias sociais pode ser útil para monitorar ou prever mudanças de humor no TB. Mais estudos longitudinais e prospectivos devem ser realizados para que se possa ter uma noção mais clara da relação das métricas extraídas de mídias sociais com o transtorno bipolar.

ABSTRACT

The symptoms of bipolar disorder (BD) involve changes in mood, cognition and behavior, which is also related to an important social cognitive impairment, making them less socially engaged. Social media are important both for promoting mental health on the Internet and for evaluating patients. However, very little is known about its actual effect in clinical practice. These media can be useful for the research area and for the clinic by observing this way of expression of the patient as a whole, as the virtual world becomes more and more part of the routine of many people. In this paper, we evaluate how social media resources can be used as clinical predictors of depression in BD and also as promoters of mental health on the Internet. In the first article of this thesis, we chose to study the BuzzFeed Mental Health Week (BFMHW) because, in December 2015, BuzzFeed promoted the Mental Health Week. We used social media metrics to measure the impact of content: exposure, influence, and engagement. In all, 44 videos and posts were analyzed. Overall, the analysis suggests that the larger the number of social media platforms reached by a post, the higher the viewing rates. In the second and the main article of this thesis we used psycholinguistic resources and Facebook usage data extracted from the social media of patients with BD. The Linguistic Inquiry Word Count (LIWC) was analyzed with machine learning. We verified whether Facebook usage metrics or semantic content analysis of people with BD could predict the mood status assessed through a NIMH Life Chart. The main finding of the second article shows that the LIWC vocabulary can indicate only a predictive tendency of bipolar depression when associated with variables known in the literature by the classic predictive trait, such as age, sex and years of study (AUC 86.7%). Once these variables are removed, the predictive value loses its strength (AUC 53.5%). The volume of use of FB (status update, photo postings, likes and shares) also pointed out only a tendency to predict bipolar depression (AUC 60%). This result shows that both LIWC and FB use data are important resources for directing predictive trends for bipolar depression through Internet use. These results may provide evidence that the use of social media may be useful for monitoring or predicting mood changes in BD. Further studies should be performed to provide a clearer understanding of the relationship between metrics extracted from social media and bipolar disorder.

1. APRESENTAÇÃO

Este trabalho consiste na tese de doutorado intitulada *“Avaliação de mídias sociais on-line como preditoras de episódios depressivos no transtorno bipolar e promotoras de saúde mental na internet”*, apresentada ao Programa de Pós-Graduação em Psiquiatria e Ciências do Comportamento da Universidade Federal do Rio Grande do Sul, em 29 de maio de 2018.

O projeto intitulado *“O impacto dos transtornos mentais no uso de internet e redes sociais on-line”* foi aprovado pelo Comitê de Ética do GPPG do Hospital de Clínicas de Porto Alegre, sob número 14-0400, de responsabilidade da pesquisadora supervisora Prof. Marcia Kauer Sant’Anna.

O trabalho é apresentado em quatro partes, na ordem que segue:

- 1 Introdução, Revisão da Literatura, Justificativa, Hipóteses e Objetivos
- 2 Artigo 1 – *“Mental health information online: what we have learned from social media metrics of BuzzFeed’s mental health week”*
- 3 Artigo 2 – *“Digital phenotype of bipolar depression: a machine-learning approach based on Facebook data”*
- 4 Conclusões e considerações finais.

2. INTRODUÇÃO

O Transtorno bipolar (TB) é um transtorno psiquiátrico que se caracteriza por significativas oscilações do humor. Seus sintomas envolvem alterações no humor, na cognição e no comportamento, sendo que a intensidade é variável, acarretando prejuízos no desempenho das atividades diárias, além de sofrimento pessoal. O TB é relacionado a um importante prejuízo cognitivo e sabe-se que os transtornos mentais afetam a cognição social do paciente, tornando-o menos engajado socialmente. A capacidade de um ser humano de agrupar-se em redes sociais, on-line e off-line, está associada à sua funcionalidade e cognição. Pessoas com bom suporte social possuem sobrevida média mais longa do que aqueles que vivem vidas mais solitárias.

Um desengajamento de redes sociais causado por transtornos psiquiátricos, assim, pode gerar uma menor qualidade de vida e conseqüente diminuição das condições físicas e psicológicas. Para lidar com as dificuldades causadas pelo TB, é natural que as pessoas procurem ajuda onde quer que esteja disponível, e as mídias sociais podem ter um papel nesse sentido. Também sabe-se que as redes sociais influenciam as decisões relativas à saúde mental e as pessoas dependem cada vez mais de redes on-line e off-line para obter apoio e alívio, gerando extensos registros de dados sobre seu comportamento e estados de humor. Conteúdos postados em SNS podem influenciar no humor dos usuários dessas mídias e as mídias sociais estão emergindo como um recurso para a saúde mental, fornecendo apoio social e redução para o estigma.

As intervenções on-line também têm a capacidade de avançar um pouco, permitindo que as pessoas desenvolvam valiosas habilidades de autogestão e obtenham conhecimentos mais avançados para gerenciar melhor sua condição da privacidade de suas próprias casas. Considerando que evolução da tecnologia tem um grande impacto em situações da vida diária, em particular, na atualização de distribuição de informação e processos de comunicação em geral, a obtenção de informações adequadas pode ser um ponto de partida para que as pessoas procurem tratamentos adequados. Neste trabalho, avaliamos como os recursos de mídias sociais podem ser utilizados como preditores clínicos de depressão no TB e também como promotores de saúde mental na internet.

No primeiro artigo deste trabalho, escolhemos estudar a Semana de Saúde Mental do BuzzFeed (BFMHW) pois, em dezembro de 2015, BuzzFeed promoveu a Semana de Saúde Mental (BuzzFeed, on-line, 2017). Vários artigos foram publicados em seu site, com abordagens consistentes discutindo problemas e transtornos mentais. A iniciativa resultou em um compartilhamento massivo de informações sobre saúde mental nas mídias sociais. O uso de métricas de mídias sociais pode ser interessante para medir o impacto do conteúdo e criar maneiras de informar e promover a saúde mental on-line. As categorias mais utilizadas são exposição, influência e engajamento.

As mídias sociais também são ricas em informações postadas pelas pessoas. Estas informações possuem uma riqueza enorme de conteúdo semântico, que pode revelar insights surpreendentes sobre seus usuários. A utilidade de tais informações na área da psiquiatria é evidente, já que as redes sociais podem funcionar como uma janela para compreender processos complexos, tais como as variações de humor em condições como o transtorno bipolar. Diversos métodos automatizados de análise de conteúdo podem ser utilizados para a análise de texto em grande escala, sem interferência direta dos pesquisadores. Um dos mais usados é o Linguistic Inquiry Word Count (LIWC). No segundo artigo deste trabalho utilizamos recursos psicolinguísticos extraídos das mídias sociais, usando o LIWC e análises com machine learning. Estes dados podem fornecer insights sobre como as pessoas interagem e comunicam sobre sua doença umas às outras.

Neste trabalho, também será investigado se as métricas de uso do Facebook ou a análise do conteúdo semântico de pessoas com Transtorno Bipolar correlacionam-se com o estado de humor avaliado através de escala clínica retrospectiva validada (NIMH Life Chart). Estes resultados podem fornecer evidências de que o uso de mídias sociais pode ser útil para monitorar ou prevenir mudanças de humor no TB.

3. REVISÃO DA LITERATURA

3.1. Transtorno bipolar

O Transtorno bipolar (TB) é um transtorno psiquiátrico que se caracteriza por significativas oscilações do humor. As variações costumam ocorrer entre dois pólos: a mania (período de humor persistentemente elevado, expansivo ou irritável), e a depressão (período de humor predominantemente deprimido) (Sajatovic, 2005). Dados estatísticos indicam que uma em cada 100 pessoas no mundo, aproximadamente, pode apresentar a doença embora evidências sugere que essas taxas podem chegar a 5% quando se considera o espectro bipolar (Hirschfeld e cols, 2005; Kessler e cols, 2006). Os sintomas envolvem alterações no humor, na cognição e no comportamento, sendo que a intensidade dos sintomas é variável, acarretando prejuízos no desempenho das atividades diárias, além de sofrimento pessoal (Sajatovic, 2005). É uma patologia mental complexa de etiologia multifatorial, recorrente e potencialmente grave, que está associada a elevadas taxas de morbidade clínica (Kilbourne et al., 2004). O TB é a sexta causa de incapacitação para o trabalho na faixa etária entre 15 e 44 anos (Coryell et al., 1993). O início do transtorno frequentemente ocorre no fim da adolescência, o que aumenta o impacto sobre os anos produtivos do indivíduo (Sajatovic, 2005).

3.1.1. Psicoeducação e Transtorno Bipolar

A psicoeducação é uma abordagem psicossocial essencial para o TB, sendo considerada uma intervenção complementar ao tratamento farmacológico e mencionada nos protocolos clínicos e diretrizes terapêuticas do Brasil e outros países. Inúmeros estudos tem mostrado que pacientes com TB psicoeducados aderem melhor ao tratamento farmacológico, possuem maior conhecimento e domínio sobre a doença (Colom et al., 2005; Colom et al., 2009). Conseqüentemente, isto deve facilitar o autocuidado e o auto monitoramento do paciente assim como deve diminuir a sobrecarga familiar (Reinares et al., 2008; Reinares et al., 2010).

A psicoeducação pode ter um efeito positivo no tratamento, já que a efetividade de abordagem terapêutica apenas com psicofármacos na prática clínica não parece ser condizente com a eficácia demonstrada na maioria dos ensaios clínicos (Scott and Pope, 2002). Em parte, isto deve-se a falta de adesão aos tratamentos de pacientes com doenças crônicas e, em especial, em psiquiatria. No TB, estima-se que 18-50% dos pacientes apresentem falhas no cumprimento terapêutico durante algum período da doença (Rosa et al., 2007). A má adesão ao tratamento está relacionada com a persistência dos sintomas de humor, mais recaídas e hospitalizações assim como um pior funcionamento cognitivo e psicossocial (Colom et al., 2005). Portanto, melhorar as taxas de adesão ao tratamento é fundamental para garantir a recuperação sintomática e funcional dos portadores de TB, diminuindo o sofrimento assim como reduzindo gastos públicos. As mídias sociais aliadas às estratégias de psicoeducação podem ser importantes na recuperação de pacientes com TB.

3.1.2. Alterações cognitivas e funcionais no transtorno bipolar

Alterações cognitivas e funcionais têm sido associadas ao TB (Martinez-Aran et al., 2004). O TB é relacionado a um importante prejuízo cognitivo, o qual é mais acentuado durante episódios de humor, mas parece persistir durante a eutímia (Martinez-Aran et al., 2004). O prejuízo social em pacientes com transtornos mentais tem sido investigado através da cognição social, que envolve a capacidade de compreender e responder aos pensamentos e sentimentos de outras pessoas (Cusi et al., 2012).

As principais disfunções relatadas incluem prejuízo da função executiva e memória declarativa (Torres et al., 2007). Alterações na atenção, concentração e memória emocional também foram demonstradas nos pacientes com transtornos mentais. Mesmo um déficit cognitivo leve pode prejudicar o desempenho na vida social e vocacional.

A cognição social refere-se a processos cognitivos pelos quais as pessoas entendem e atribuem sentido aos outros e a si mesmos (Renner et al., 2012). A aptidão de integrar informação contextual com interpretações para gerar significado é um aspecto fundamental da cognição social (Baez et al., 2013). A capacidade de

um ser humano de agrupar-se em redes sociais, on-line e *off-line*, está associada à sua funcionalidade e cognição. Ainda, de acordo com Holt-Lunstad et al. (2010), pessoas com bom suporte social possuem sobrevida média mais longa do que aqueles que vivem vidas mais solitárias. Esta pesquisa sugere que todos nós estamos propensos a desfrutar de benefícios de saúde se tivermos vidas sociais bem engajadas. Propõe, ainda, a inclusão do agente “baixo índice de relacionamento social” como fator de risco para problemas de saúde, assim como o tabagismo, dietas e exercícios.

Os transtornos mentais afetam a cognição social do paciente, tornando-o menos engajado socialmente. Ter contatos sociais resulta em pessoas mais felizes e saudáveis, física e mentalmente (Heaney et al., 2008). Ainda, Cohen et al. (1997) explica que uma rede social diversificada está associada a uma maior qualidade de vida. Um desengajamento de redes sociais causado por transtornos psiquiátricos, assim, pode gerar uma menor qualidade de vida e conseqüente diminuição das condições físicas e psicológicas.

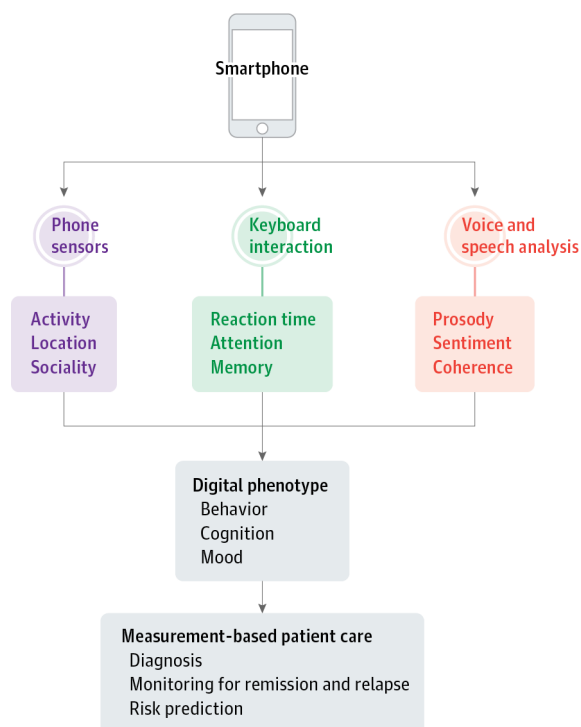
Estes déficits apresentados por pacientes com transtornos mentais estariam relacionados a uma deficiência na capacidade de interpretar contextualmente as situações diárias. Sendo assim, o entendimento dos fatores associados a uma cognição prejudicada nos transtornos mentais é muito importante para desvendar a forma como os pacientes são afetados em sua vida social e profissional, além de ser determinante para o desenvolvimento de estratégias para reabilitação e prevenção dessa condição.

Ainda que déficits cognitivos tenham sido consistentemente identificados em amostras de pacientes com TB (Zubieta et al., 2001), não está claro como esta relação afeta as possibilidades de uso da internet e redes sociais *on-line* e, conseqüentemente, a formação de vínculos sociais, funcionalidade e qualidade de vida. A internet tem se tornado uma ferramenta importante de inserção social e também no mercado de trabalho (Martini TC et al., 2013). Além disso, a rede virtual tem sido fonte crescente de informação e até de psicoeducação para pacientes e familiares com TB (Ziebland S & Wyke S, 2012). Para lidar com as dificuldades causadas pelo TB, é natural que as pessoas procurem ajuda onde quer que esteja disponível, e as mídias sociais podem ter um papel nesse sentido.

3.2. Fenótipo digital e seu papel na saúde mental

Fenótipo digital é o termo usado para descrever a nova abordagem de medição do comportamento através de sensores de smartphones, interações com teclado e diversas características de voz e discurso (Jain SH et al., 2015). Os sensores medem dados de comportamento, cognição e humor. Esse é o pressuposto de uma área emergente, mapeamento do fenótipo digital, que tenta avaliar o bem-estar das pessoas com base em suas interações com os dispositivos. Esta área recente está ganhando espaço na pesquisa e prática clínica (Insel T, 2017, ver figura 1).

Figura 1.



Fonte: Insel T, 2017

Enquanto as pesquisas atuais indicam que a manifestação de transtorno bipolar em cada pessoa é um resultado único de sua composição genética e ambiente circundante, os critérios clínicos atuais colocam os pacientes em categorias precisas, mas não altamente específicas. Para Matthews M et al. (2017) a longo prazo, o uso de tecnologia on-line pode ter o potencial de fornecer avaliações

mais sutis, por meio do que poderíamos chamar de fenotipagem mediada por tecnologia, da manifestação de TB de cada indivíduo.

Neste contexto, o uso cada vez maior das mídias sociais também poderá fazer parte desta fenotipagem. O Facebook, atualmente a rede social *on-line* mais utilizada no mundo, teve uma média de 1,4 bilhão de visitantes diários ativos em dezembro de 2017, com 82 milhões de usuários ativos no Brasil em novembro de 2016 (Facebook Newsroom Brasil, acessado 20 de abril de 2018). As redes sociais influenciam as decisões relativas à saúde mental (Karasouli E & Adams A, 2014) e as pessoas dependem cada vez mais de redes *on-line* e *off-line* para obter apoio e alívio, gerando extensos registros de dados sobre seu comportamento e estados de humor (Shen G et al. 2017).

As pessoas parecem procurar informações, apoio e relacionamentos com outras pessoas *on-line*, vivenciando serviços de saúde e afetando o seu comportamento (Kelly, Jenkinson & Ziebland, 2013). As mídias sociais ou SNS (Sites de Redes Sociais) têm um imenso potencial para reduzir o estigma da saúde mental (Christensen, 2014, *on-line*). As SNS tendem a desenvolver ferramentas que permitem que as pessoas busquem apoio e envolvimento com as experiências de outras pessoas, o que afeta a tomada de decisões e o ajuste à condição do indivíduo (Ziebland S & Wyke S, 2012). Ao compartilhar conteúdo, as pessoas procuram parceiros para endossar suas ideias e estilo de vida. Seja qual for o assunto, a atenção que as pessoas obtêm *on-line* com a exposição de seus pensamentos pode atuar como um reforço para suas posições e exercer influência em suas vidas (Kietzmann JH et al., 2011).

A possibilidade de compartilhar histórias na Internet permite que as pessoas identifiquem seus problemas nos outros. Há o sentimento de pertencer a um grupo quando as pessoas enfrentam problemas e preocupações semelhantes (Naslund et al., 2016). Além disso, quando a informação vem de outros com a mesma condição de saúde, as pessoas tendem a confiar mais do que em profissionais de saúde (Ziebland S & Wyke S, 2012). Em tempos de *fake news*¹, esta é uma das principais preocupações para quem tem como objetivo promover conteúdo adequado nas redes.

¹ Fake news (termo comum em inglês para “notícias falsas”) é a distribuição deliberada de desinformação ou boatos via mídias de comunicação, principalmente *on-line*, nas mídias sociais.

Como resultado do alto engajamento dos usuários em mídias sociais, os estudos que ligam os SNS e as informações psicológicas sobre atitudes e comportamentos vêm aumentando (Young SD, 2014). Estudos recentes mostram como os conteúdos postados em SNS podem influenciar no humor dos usuários dessas mídias. Cientistas da Universidade de Cornell analisaram quase 700 mil perfis de usuários do Facebook e observaram que usuários apresentados a informações positivas, utilizam palavras positivas em suas publicações. No entanto, pessoas expostas a conteúdos negativos, utilizam palavras negativas em suas atualizações (Kramer ADI, Guillory JE & Hancock JT, 2014), o que poderia afetar diretamente pessoas que podem sofrer de depressão. As pessoas transferem emoções positivas e negativas umas para as outras (Hatfield E, Cachopo JT e Rapson RL, 1993). Pela internet, estados de humor mais duradouros (depressão e felicidade) também podem ser transferidos através das redes (Fowler JH & Christakis NA, 2008; Rosenquist JN, Fowler JH & Christakis NA, 2011).

Figura 2.



Fonte: Reece A, Danforth C, 2017

Outro estudo desenvolveu um recurso capaz de mapear as fotos do Instagram que possa indicar comportamento depressivo. Em uma amostra de 44 mil fotos, os pesquisadores utilizaram uma ferramenta que analisou as cores utilizadas, metadados e expressões faciais. Por fim, os usuários foram avaliados por médicos e a taxa de acerto foi de 70%, mais assertiva que o esperado. O estudo identificou que

fotos postadas por pessoas depressivas costumam exibir tons frios e escuros de azul e cinza (Reece A, Danforth C, 2017).

As mídias sociais estão emergindo como um recurso para a saúde mental, fornecendo apoio social e redução para o estigma. Recentemente, o Facebook anunciou que iria integrar ferramentas de prevenção contra suicídio em tempo real (Rosen G, 2017, *on-line*). A empresa conecta pessoas que precisam de ajuda trabalhando com reconhecidas organizações como o Centro de Valorização da Vida (CVV) e a SaferNet no Brasil, através de bate-papo ao vivo no Facebook Messenger. Além disso, ainda existe uma página com conteúdo para quem procura ajuda, este *site* possui informações das mais diversas sobre prevenção de suicídio². As mídias sociais realmente podem ser um poderoso aliado para alertar os usuários sobre o risco de suicídio e assim, evitá-los. Entre os tantos papéis das mídias sociais que estamos analisando neste trabalho, este talvez seja o mais importante.

A internet remove muitas barreiras comuns ao acesso a informações de saúde especializadas, como localização geográfica, status socioeconômico e disponibilidade de clínicos adequadamente treinados (Lauder, Chester e Berk, 2007). Embora existam preocupações com a qualidade e precisão de algumas informações *on-line*, a internet é particularmente popular entre aqueles com diagnósticos de saúde mental (Lam-Po-Tang & McKay, 2010). Isso apresenta uma oportunidade e desafio interessante para os clínicos, com muitos pacientes e famílias tratando a consulta presencial como segunda opinião após a primeira verificação no "Dr. Google" (Mac Neily, 2013). Estas questões ressaltam a importância de compartilhar recursos de saúde mental baseados em evidências *on-line* para garantir uma informação precisa, de alta qualidade e facilmente acessível.

As intervenções *on-line* podem ir além, permitindo que as pessoas desenvolvam valiosas habilidades de autogestão e obtenham conhecimentos mais avançados para gerenciar melhor sua condição da privacidade de suas próprias casas (Lauder, Chester e Berk, 2007). Há evidências que apoiam o uso de programas *on-line* para outras condições de saúde mental, particularmente aqueles que visam a depressão (Andersson et al., 2005; Christensen, Griffiths & Jorm, 2004; Mackinnon, Griffiths & Christensen, 2008; Meyer et al., 2009) e estas abriram o caminho para intervenções *on-line* mais específicas para o transtorno bipolar (TB).

² <https://www.facebook.com/safety/suicideprevention>

Existem vários aplicativos para o TB que foram submetidos ou estão sendo avaliados (Hidalgo-Mazzei et al., 2015).

Considerando que evolução da tecnologia tem um grande impacto em situações da vida diária, em particular, na atualização de distribuição de informação e processos de comunicação (Pew Research Center, 2015) em geral, a obtenção de informações adequadas pode ser um ponto de partida para que as pessoas procurem tratamentos adequados (Ziebland S & Wyke S, 2012). Este acesso generalizado à informação na era digital tem redesenhado, ainda, a maneira como os pacientes e suas famílias se envolvem e acessam a informação, que se transformou em um aspecto importante do tratamento e cuidados em saúde mental. Muitos problemas de saúde e, em particular, distúrbios de saúde mental beneficiam-se enormemente de estratégias de psicoeducação (Colom et al., 2009; Reinares et al., 2010).

Mais, a internet é um caminho conveniente para a disseminação de informação de saúde e muitos cuidadores de pacientes com transtornos psiquiátricos buscam estas informações de suporte sobre condições de saúde de seus entes (Berk et al., 2013; Lauder et al., 2013; Leitan et al., 2015). Alguns estudos já investigaram como os pacientes com diagnóstico em TB mantêm e se relacionam com os seus grupos sociais (Kauer-Sant'anna M et al., 2008), também em mídias sociais (Martini et al., 2013). Neste trabalho, serão avaliados como os recursos de mídias sociais podem ser utilizados como preditores clínicos de depressão no Transtorno Bipolar e também como promotores de saúde mental na internet.

3.3. Mídias sociais e promoção de saúde mental

Embora exista uma grande quantidade de informações precisas sobre saúde mental disponíveis *on-line* e um número crescente de sites focados neste conteúdo, o estigma ainda é comum e é agravado por dados falsos e imprecisos que se espalham pelas redes sociais (Mackey TK, Schoenfeld VJ, 2016). Portanto, o padrão de distribuição de informações *on-line* pode influenciar positivamente o tratamento ou atrasar o tratamento e a adesão adequados, promovendo o estigma e sugerindo opções de tratamento ineficazes ou imprecisas.

Aproveitando as estratégias *on-line* mais eficazes para disseminar o conhecimento adequado, poderemos reduzir o estigma e aumentar a inclusão social de pessoas com doenças mentais (Yamaguchi S, Mino Y, Uddin S, 2011). Além disso, pacientes com dificuldades como ansiedade social, depressão e introversão parecem fornecer insights sobre seu estado de saúde mental nas mídias sociais (Cox-George C, 2015). Assim, as mídias sociais poderiam ser uma estratégia útil para promover o envolvimento em intervenções de tratamento e pesquisa (Crutzen R, Ruitter RA, de Vries NK, 2014; Betton V et al., 2015), especialmente quando um grande número de estudos atualmente enfrenta dificuldades para recrutar participantes (Christensen H, Griffiths KM, Farrer L, 2009).

3.3.1. Estudo do caso do BuzzFeed

O acesso a informações precisas pode ser um ponto de partida para os pacientes que desejam buscar e receber tratamento (Ziebland S, Wyke S, 2012), portanto, pode ser útil estudar o caso de um site que recebeu milhares de visitantes falando sobre saúde mental usando estratégias de marketing de conteúdo e mídia social.

Figura 3.



Fonte: Smith B, Franl Z, 2015, *on-line*.

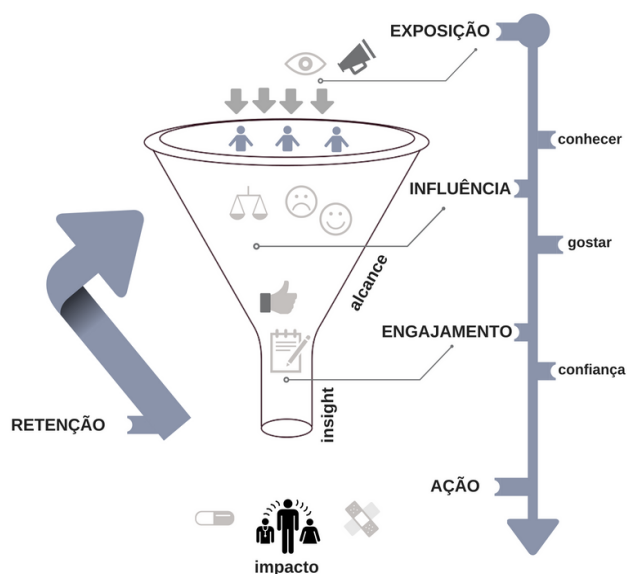
Escolhemos estudar a Semana de Saúde Mental do BuzzFeed (BFMHW) porque foi um evento focado em saúde mental, promovido por um site que tem um

público global e é pioneiro no campo das notícias e entretenimento sociais. O BuzzFeed publica posts em muitas plataformas de mídia social e abrange uma ampla gama de tópicos usando postagens diversas e criativas, que muitas vezes tornam-se virais. Um de seus principais componentes é a associação entre conteúdo informacional e estratégias de marketing, com foco secundário em entretenimento (Tandoc Jr EC, Jenkins J, 2015). Em dezembro de 2015, o BuzzFeed promoveu a Semana de Saúde Mental (Smith B, Franl Z, 2015). Vários artigos foram publicados em seu site, com abordagens consistentes discutindo problemas e transtornos mentais. Curiosamente, os posts com uma temática sobre transtorno mental alcançaram milhões de visualizações; Por exemplo, um único post teve mais de 1 milhão de visualizações (Jonah Peretti, *on-line*, outubro de 2015). A iniciativa deste BuzzFeed resultou em um compartilhamento massivo de informações sobre saúde mental nas mídias sociais.

3.3.2. Análise de métricas e conteúdo em redes sociais

Entre as principais métricas utilizadas hoje em dia estão os recursos de marketing de conteúdo *on-line*. As empresas de marketing estão se especializando em analisar métricas e estratégias de planejamento, aumentando a popularidade de marcas e serviços. Eles criaram maneiras de medir a presença *on-line*, através de "impressões" para "cliques", de "compartilhar" para "tempo gasto" e "impactar" (Jonah Peretti, *on-line* outubro de 2015). Marketing de Conteúdo e *Inbound* (Hubspot Academy, *on-line*, 2017) são parte desses processos focados na criação e distribuição de conteúdo para atrair e reter uma audiência. O objetivo é criar compartilhamento de conteúdo viral através das mídias sociais, unindo pessoas que gostem de socializar, estar informadas e se divertir (Tandoc Jr EC, Jenkins J, 2015). O estudo das métricas de marketing de conteúdo digital pode aumentar o interesse das pessoas nas intervenções *on-line*, uma vez que o entretenimento utilizado como estratégia pode melhorar o engajamento (Crutzen R, Ruitter RA, de Vries NK, 2014).

Figura 4.



Fonte: elaborado pela autora baseada em Kelly N, 2011 e Neiger BL et al., 2012.

As métricas de mídias sociais são relacionadas à consciência da marca – quando os clientes lembram ou reconhecem um nome (Kelly N, 2011). As categorias mais utilizadas são exposição, influência e engajamento (Kelly N, 2011 e Neiger BL et al., 2012) (Figura 3). Exposição (a) mede o alcance da marca em seus esforços, usando métricas como impressões, fãs, seguidores, visitas, visualizações, menções e assinantes. Influência (b) é um olhar se as métricas são positivas, neutras ou negativas no sentimento; Comumente as variáveis são curtidas e suas variações. Engajamento (c) é um estágio que mede quantas pessoas realmente fizeram algo com a mensagem, pode ser medido por cliques, compartilhamentos, respostas, mensagens diretas, postagens e comentários.

O próximo passo é a geração de leads com as categorias finais de ação/conversão e retenção de clientes (Kelly N, 2011). A ação/conversão mede o impacto que a informação ou produto teve para o cliente, downloads de conteúdo, contribuições, assinantes e respostas (Hubspot, 2017; Kelly N, 2011). A categoria final, a retenção de clientes, é importante para determinar se o ciclo de vida do cliente está sendo renovado. Manter o cliente também é uma estratégia de vendas e manter um paciente envolvido com informações é essencial para o tratamento. A atividade final é reiniciar o ciclo, com o cliente voltando ao topo do funil (Figura 3).

O uso de métricas de mídias sociais pode ser interessante para medir o impacto do conteúdo e criar maneiras de informar e promover a saúde mental *on-line*. Neiger BL et al (2012) concluiu que a mídia social deve ser vista como uma ferramenta de apoio ao processo de mudança, uma vez que esses recursos de mídia têm o potencial de interagir com o público e melhorar a comunicação.

Tabela 1.

Categoria	Sub-categoria	Resultado avaliado	Métricas
Elementos gerais avaliados	Tópicos	Avalia sobre o que é a postagem	Assunto dos vídeos e posts
	Duração de vídeos	Avalia quanto tempo tem um vídeo	Média do numero de dias <i>on-line</i>
	Inscrições	Avalia quantas pessoas inscreveram-se em um vídeo a partir de uma postagem	Mediana do número de inscrições (para vídeos)
Métricas de Mídias Sociais	Exposição	Presença <i>on-line</i>	Visualizações, tempo <i>on-line</i> , tempo assistido, formato e conteúdo
	Influência	Sentimento positivo ou negativo	Curtidas e descurtidas
	Engajamento	Gera ação <i>on-line</i>	Comentários, compartilhamentos, respostas, contribuições, interação total
Métricas de formato e conteúdo	Padrão de narrativa	Avaliação de qual tipo de narrativa foi utilizada	Relatos, ficção, séries, áudio/ imagem e entrevistas
	Seções de conteúdo	Quais elementos são encontrados no conteúdo	Expressão, humor, informação, dicas, pop cultural, inspiração, experiência e conteúdo misto

Recursos de mídia	Avaliação de que tipo de mídia foi usada	Animações, ilustrações, gifs, depoimento, mídias mistas
Formato de publicação	Avaliação do formato da postagem	Listas, o quê, quem, por que, tempo, persona
Uso de cor	Avaliação da presença de cor	Cor, preto ou branco
Texto x Imagem	Avaliação sobre quantidades de texto e imagem	Mais texto ou imagem

Fonte: elaborado pela autora, baseada em Hubspot, 2017 e Kelly N, 2011.

3.4. Mídias sociais e preditores clínicos de depressão

Informações postadas em redes sociais possuem uma riqueza enorme de conteúdo semântico, que pode revelar insights surpreendentes sobre seus usuários. A análise automatizada de vocabulário, por exemplo, é capaz de prever características como sexo, idade e personalidade dos usuários com acurácia surpreendente (Schwartz et al., 2012; Park et al., 2014). A utilidade de tais informações na área da psiquiatria é evidente, já que as redes sociais podem funcionar como uma janela para compreender processos complexos, tais como as variações de humor em condições como o transtorno bipolar. Tanto a intensidade do uso das redes como o conteúdo e estrutura produzidos pelos pacientes, assim, podem ter correlações importantes com estas variações.

Nesse sentido, dados recentes publicados pelo grupo do Instituto do Cérebro da UFRN, nossos atuais colaboradores, sugerem que não só o conteúdo do discurso, mas também sua estrutura (avaliada através de análise dos grafos formados pelas sequências de palavras) possui valor diagnóstico na diferenciação de diferentes transtornos psiquiátricos, como a esquizofrenia e o transtorno bipolar (Mota et al. 2012, Mota et al., 2014). A utilização de fragmentos de texto extraídos da atividade dos pacientes nas redes sociais nos permitiria testar as abordagens desenvolvidas em laboratório em um ambiente mais próximo da vida real, já que

utilizarão o discurso escrito que os pacientes utilizam para comunicar-se em sua rotina diária.

3.4.1. Análise de conteúdo semântico

Diversos métodos automatizados de análise de conteúdo podem ser utilizados para a análise de texto em grande escala, sem interferência direta dos pesquisadores. Um dos mais usados é o *Linguistic Inquiry Word Count* (LIWC) (Pennebaker et al., 2007), um instrumento tradicional de análise de conteúdo que classifica palavras em categorias específicas e foi traduzido para o português (Balage Filho et al., 2013). O LIWC calcula o número de vezes que certos grupos de palavras aparecem e as relações entre palavras diferentes por meio de uma análise de texto automatizada. O dicionário inclui 64 categorias que medem componentes emocionais, cognitivos e estruturais contidos no texto. As categorias semânticas relacionadas aos processos afetivos estão na literatura frequentemente relacionadas aos estudos sobre depressão: (a) emoção positiva, (b) emoção negativa, (c) ansiedade, (d) raiva e (e) tristeza (anexo a).

No entanto, outras metodologias incipientes também podem ser utilizadas, tais como a análise semântica latente (LSA, do inglês *latent semantic analysis*), que analisa a distância do vocabulário utilizado de palavras chave a partir da análise de um *corpus* padrão de texto (Cohen et al., 2008, Elvevag et al., 2010), para analisar a proximidade do discurso dos pacientes de conceitos representativos dos estados de mania e depressão.

Vários estudos têm proposto o uso de mídias sociais para a detecção de transtornos mentais. Nguyen et al (2017) descobriram que os recursos psicolinguísticos extraídos das mídias sociais, usando o LIWC e análises com machine learning, podem fornecer insights sobre como as pessoas deprimidas interagem e comunicam sobre sua doença a outras pessoas. Este grupo também descobriu que características como afeto, conteúdo escrito e estilo de escrita são expressos de forma diferente entre comunidades de depressão e outras comunidades *on-line* (Nguyen et al, 2014). Outro estudo sugere que o processamento de linguagem e machine learning podem permitir a prospecção em grande escala das mídias sociais (Guntuku SC et al., 2017).

Marcadores de mídia social também têm sido usados para identificar diferenças lingüísticas específicas entre pessoas com esquizofrenia e controles (Birnbaum ML et al., 2017). Choudhury et al. (2013) analisaram informações comportamentais (através de postagens em mídias sociais), construindo um classificador estatístico que estimava o risco de depressão antes do início relatado. Pesquisadores realizaram alguns estudos no Twitter: Birjali M et al. (2017) descobriu que essa plataforma poderia ser usada para analisar a depressão *on-line*; Braithwaite et al. (2016) descobriram que pessoas com alto risco de suicídio poderiam ser facilmente diferenciadas daquelas que não são baseadas na atividade do Twitter e Shen G et al. (2017) propuseram um modelo de aprendizagem de dicionário depressivo multimodal para detectar os usuários deprimidos no Twitter.

No entanto, é saliente a percepção de que menos estudos escolheram o Facebook como sua principal mídia para coletar dados *on-line* das pessoas para detectar resultados psiquiátricos. Apenas alguns estudos utilizaram esta plataforma: Settani M & Marengo D (2015) mostraram que usuários com níveis mais elevados de depressão e ansiedade expressavam emoções negativas no Facebook com maior frequência. Embora os pesquisadores descobrissem que os posts do Facebook tinham dados ruidosos, um estudo teve sucesso em prever depressão usando o Facebook, LIWC e ferramentas de machine learning (Nguyen T, Armstrong W, Shrivastava A, *on-line*).

Neste trabalho, também será investigado se as métricas de uso do Facebook ou a análise do conteúdo semântico de pessoas com Transtorno Bipolar correlacionam-se com o estado de humor avaliado através de escalas clínicas retrospectivas validadas. Estes resultados podem fornecer evidências de que o uso de mídias sociais pode ser útil para monitorar ou prever mudanças de humor no TB.

4. JUSTIFICATIVA

As mídias sociais são ferramentas importantes tanto para a promoção de saúde mental na internet quanto para avaliação de pacientes. No entanto, muito pouco ainda se sabe com relação ao seu real efeito na prática clínica. Estas mídias podem ser úteis para a área de pesquisa e para a clínica através da observação desta forma de expressão do paciente como um todo, pois o mundo virtual faz cada vez mais parte da rotina de muitas pessoas. Para realizar esta observação geral, é preciso analisar o seu comportamento e como esta via de relação com o mundo influencia a funcionalidade dos pacientes com transtorno bipolar no cotidiano.

4.1. Justificativa para o artigo 1

Pode ser valioso estudar um caso bem-sucedido de um site que tenha recebido milhares de visitantes em suas páginas falando sobre saúde mental, usando marketing de conteúdo e estratégias de mídia social. Desta forma, buscaremos estudar métricas de marketing extraídas durante a Semana de Saúde Mental (SSM) do BuzzFeed, em dezembro de 2015, o que pode nos ensinar sobre fatores importantes para o envolvimento *on-line* efetivo que pode abrir caminho para futuras intervenções na *web*.

Escolhemos estudar a BFMHW porque foi produzido conteúdo focado na saúde mental por um site pioneiro no setor de empresas de notícias e entretenimento social norte-americano com público global. O BuzzFeed difunde posts em um formato atraente e está envolvido em muitas plataformas de mídias sociais. Um dos seus principais aspectos é a associação de conteúdo com estratégias de entretenimento e marketing. Abrange uma ampla gama de tópicos e tem muitas maneiras criativas de apresentar suas postagens, tornando-as "virais" usando conteúdo diversificado e sendo presente em vários sites de redes sociais *on-line*, conhecida como a estratégia principal do BuzzFeed (Tandoc Jr EC & Jenkins J, 2015). Durante a SSM, curiosamente, as postagens com uma temática do transtorno mental alcançaram milhões de pontos de vista; Por exemplo, uma única publicação tinha mais de 1 milhão de visualizações (Peretti, 2015). A iniciativa do BuzzFeed

resultou em uma enorme partilha de informações sobre saúde mental nas mídias sociais.

4.2. Justificativa para o artigo 2

As informações postadas nas mídias sociais possuem uma abundância de conteúdo semântico, o que pode revelar uma infinidade de insights sobre seus usuários. A análise automatizada de vocabulário pode prever traços como gênero, idade e personalidade dos usuários com precisão notável (Schwartz et al., 2012; Park et al., 2014). A utilidade de tais informações na psiquiatria é evidente, uma vez que as redes sociais podem funcionar como uma janela para compreender processos complexos, como alterações de humor no transtorno bipolar. Tanto a intensidade do uso das mídias sociais quanto o conteúdo produzido pelos pacientes podem ter correlação com alterações do humor, oferecendo a possibilidade de detecção precoce e acompanhamento dessas alterações.

4.3. Hipóteses

A hipótese do artigo principal (artigo 2) deste trabalho é baseada na estrutura e no conteúdo semântico das postagens, medidas através do LIWC, no Facebook e no estado de humor indicados pela NIMH Life Chart, coletado retrospectivamente um ano. O conteúdo das postagens dos pacientes com TB poderá servir de base para a criação de um modelo de predição da depressão no transtorno bipolar através de características do grupo afetivo (sentimentos positivos ou negativos, raiva, ansiedade e tristeza) do vocabulário LIWC, utilizado neste trabalho. Ainda, é possível que o volume de uso do Facebook medido através de métricas de mídias sociais extraídos da web, também possa prever a depressão dos pacientes com transtorno bipolar entrevistados.

A perspectiva para a análise do caso do SSM do BuzzFeed (artigo 1) e mídias sociais (Facebook, Twitter e YouTube) é a de que as estratégias de marketing utilizadas na propagação do conteúdo possam ser relacionadas, abrangendo uma ampla gama de tópicos, que poderão ser úteis para a produção de novos conteúdos de promoção de saúde mental nas mídias.

4.4. Objetivos

4.4.1. Artigo 1

Geral: Analisar as interações da Semana de Saúde Mental (BFMHW) do BuzzFeed em seu próprio site e em plataformas de mídia social relacionadas (Facebook, Twitter e YouTube) usando métricas de entrega de informações em tópicos de saúde mental.

Específicos: Identificar estratégias de marketing de redes sociais a serem usadas para promover a saúde mental e reduzir o estigma em futuras intervenções *on-line*, através da análise do caso da Semana de Saúde Mental (SSM) do BuzzFeed e mídias sociais (Facebook, Twitter e YouTube).

4.4.2. Artigo 2

Geral: Com base na estrutura e no conteúdo semântico das postagens no Facebook e no estado de humor indicados pela NIMH Life Chart, coletado retrospectivamente um ano, averiguar se o uso desta mídia social prediz a depressão no transtorno bipolar.

Específicos: Com base em métricas quanto ao volume de uso extraídas do Facebook e no estado de humor indicados pela NIMH Life Chart, coletado retrospectivamente um ano, averiguar se o uso desta mídia social prediz a depressão no transtorno bipolar.

5. ARTIGO 1

O primeiro artigo foi produzido em parte na Austrália, no período em que a autora esteve em Geelong e Melbourne na Deakin University, durante a realização do Doutorado-Sanduiche. De caráter inovador para a área, o artigo intitulado “*Mental health information online: what we have learned from social media metrics in BuzzFeed’s mental health week*” foi aceito para publicação na revista Trends in Psychiatry and Psychotherapy, em março de 2018.

Mental health information online: what we have learned from social media metrics in BuzzFeed’s Mental Health Week

Short title: Mental health information online

Thais Martini,¹ Leticia Czepielewski,¹ Daniel Prates Baldez,¹ Emma Gliddon,^{2,3,4} Christian Kielling,⁵ Lesley Berk,^{2,3} Michael Berk,^{2,3,4} Marcia Kauer-Sant’Anna^{1,5}

¹ Programa de Pós-Graduação em Psiquiatria e Ciências do Comportamento, Laboratório de Psiquiatria Molecular, Hospital de Clínicas de Porto Alegre, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, Brazil.

² Deakin University, IMPACT Strategic Research Centre, School of Medicine, Geelong, VIC, Australia.

³ University Hospital Geelong, Barwon Health, Geelong, VIC, Australia.

⁴ Orygen, The National Centre of Excellence in Youth Mental Health, the Florey Institute for Neuroscience and Mental Health and the Department of Psychiatry, University of Melbourne, Parkville, VIC, Australia.

⁵ Departamento de Psiquiatria e Medicina Legal, Hospital de Clínicas de Porto Alegre, UFRGS, Porto Alegre, RS, Brazil.

RESUMO (tradução da autora)

Introdução: A Internet tem visto um rápido crescimento no número de sites com foco em conteúdo de saúde mental. Considerando a necessidade crescente de acesso a informações precisas sobre tratamento de saúde mental, é importante entender a promoção dessas informações on-line.

Objetivo: Analisar as interações da Semana de Saúde Mental (BFMHW) do BuzzFeed em seu próprio site e em plataformas de mídia social relacionadas (Facebook, Twitter e YouTube) usando métricas de entrega de informações em tópicos de saúde mental.

Métodos: Extraímos as métricas de mídia social das 20 postagens com o maior número de interações do BuzzFeed no site da BFMHW e de 41 vídeos disponíveis na playlist do BFMHW criada pelo perfil do BuzzFeed Video no YouTube. Analisamos o formato e o conteúdo usados nos métodos de publicação do BuzzFeed, bem como as seguintes métricas de mídia social: exposição (presença *on-line*, visualizações e tempo *on-line*), influência (curtidas) e engajamento (comentários, compartilhamentos, respostas e interações do BuzzFeed).

Resultados: A análise das variáveis revelou que o envolvimento do público está associado ao número de mídias em que o conteúdo é publicado: visualizações no YouTube e compartilhamentos no Facebook (0,71, $p < 0,001$), interações totais no Facebook (0,66, $p < 0,001$) e número de interações totais no BuzzFeed (0,56, $p < 0,001$).

Conclusões: Nossos resultados sugerem que os vídeos no YouTube podem ser um importante canal de informações, incluindo atividades e envolvimento em outras mídias, como o Facebook. As informações podem ser mais eficazes para alcançar o público se forem exibidas em mais de uma mídia e incluírem experiências pessoais, algum humor no conteúdo e informações detalhadas sobre o tratamento.

Palavras-chave: Saúde mental *on-line*; métricas de mídia social; engajamento; BuzzFeed; Semana de Saúde Mental; psiquiatria.

Mental health information online: what we have learned from social media metrics in BuzzFeed's Mental Health Week

Short title: Mental health information online

Thais Martini,¹ Leticia Czepielewski,¹ Daniel Prates Baldez,¹ Emma Gliddon,^{2,3,4} Christian Kielling,⁵ Lesley Berk,^{2,3} Michael Berk,^{2,3,4} Marcia Kauer-Sant'Anna^{1,5}

¹ Programa de Pós-Graduação em Psiquiatria e Ciências do Comportamento, Laboratório de Psiquiatria Molecular, Hospital de Clínicas de Porto Alegre, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, Brazil.

² Deakin University, IMPACT Strategic Research Centre, School of Medicine, Geelong, VIC, Australia.

³ University Hospital Geelong, Barwon Health, Geelong, VIC, Australia.

⁴ Orygen, The National Centre of Excellence in Youth Mental Health, the Florey Institute for Neuroscience and Mental Health and the Department of Psychiatry, University of Melbourne, Parkville, VIC, Australia.

⁵ Departamento de Psiquiatria e Medicina Legal, Hospital de Clínicas de Porto Alegre, UFRGS, Porto Alegre, RS, Brazil.

Corresponding author:

Thaís Cunha Martini

Laboratório de Psiquiatria Molecular – Hospital de Clínicas de Porto Alegre

Universidade Federal do Rio Grande do Sul

Rua Ramiro Barcelos, 2350

Tel.: +55 51 33598845

E-mail: tmartini@hcpa.edu.br

Sources of support: Fundo de Incentivo a Pesquisa e Eventos – Hospital de Clínicas de Porto Alegre; National Science and Technology Institute for Translational Medicine (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior and Conselho Nacional de Desenvolvimento Científico e Tecnológico).

Conflict of interest declaration: None.

Word count: 4,250

Number of tables and figures: 3 tables and 4 figures

Date of the last literature review: March 10th, 2018

Abstract

Introduction: The Internet has seen rapid growth in the number of websites focusing on mental health content. Considering the increased need for access to accurate information about mental health treatment, it is important to understand the promotion of this information online.

Aim: To analyze BuzzFeed's Mental Health Week (BFMHW) interactions on its own website and in related social media platforms (Facebook, Twitter and YouTube) using metrics of information delivery in mental health topics.

Methods: We extracted social media metrics from the 20 posts with the highest number of BuzzFeed interactions on the BFMHW website and from 41 videos available on the BFMHW playlist created by the BuzzFeed Video profile on YouTube. We analyzed the format and content used in BuzzFeed's publishing methods as well as the following social media metrics: exposure (presence online, views and time online), influence (likes) and engagement (comments, shares, replies and BuzzFeed interactions).

Results: Analysis of the variables revealed that audience engagement is associated with the number of medias in which the content is published: views on YouTube and shares on Facebook (0.71, $p < 0.001$), total interactions on Facebook (0.66, $p < 0.001$) and BuzzFeed number of total interactions (0.56, $p < 0.001$).

Conclusions: Our results suggest that videos on YouTube may be an important information channel, including activity and engagement on other medias such as Facebook. Information may be more effective in reaching the audience if it is delivered in more than one media and includes personal experiences, some humor in content and detailed information about treatment.

Keywords: Mental health online; social media metrics; engagement; BuzzFeed; Mental Health Week; psychiatry.

Introduction

Technology has had a great impact on our daily lives, particularly on information distribution and communication processes.¹ The current mode of information distribution has redesigned the way how people search for health information, and it has become an important aspect of treatment and care in mental health. Access to information may aid treatment, as many health problems and mental health disorders benefit from psychoeducational strategies.^{2,3} Granting broad access to mental health content online has made it possible for people to access information and support 24/7.

While there is a vast amount of accurate mental health information available online and a growing number of websites focused on mental health content,⁴ stigma is still common and is aggravated by false, inaccurate data that spreads over social networks.⁵ Therefore, the pattern of online information distribution may either influence treatment positively, or it may delay adequate treatment and adherence by fostering stigma and suggesting ineffective or inaccurate treatment options.

By taking advantage of the most effective online strategies used to disseminate adequate knowledge, we may be able to reduce stigma and enhance social inclusion of people with mental illness.⁶ Furthermore, patients with difficulties such as social anxiety, depression and introversion seem to provide an insight into their mental health status on social media.⁷ Thus, social media could be a useful strategy to promote engagement in treatment interventions and research,^{8,9} especially when a large number of studies currently face difficulties recruiting participants.¹⁰

Access to accurate information could be a starting point for patients to wish to seek and receive treatment,¹¹ therefore it may be useful to study the case of a website that has received thousands of visitors talking about mental health, using content marketing and social media strategies. We chose to study BuzzFeed's Mental Health Week (BFMHW) because it was a mental health-focused event (week) promoted by a website that has a global audience and is a pioneer in the field of social news and entertainment. BuzzFeed

publishes posts across many social media platforms and covers a wide range of topics using diverse, creative posts, which often “go viral.” One of its core components is the association between informational content and marketing strategies, with a secondary focus on entertainment.¹² In December 2015, BuzzFeed promoted the Mental Health Week.¹³ Several posts were published on their website, with consistent approaches discussing mental health problems and disorders.

Marketing companies specialize in analyzing metrics and planning strategies to increase the popularity of brands and services online. Two processes focused on creating and distributing content to attract and retain audience/customers are Inbound Marketing and Content Marketing, which consist of creating and sharing content with the objective of engaging the audience, thereby building confidence.¹⁴ The main idea behind these processes is to create viral content by sharing it via social media, managing to combine people’s needs to socialize, be informed and be entertained.¹²

Social media metrics measure online activities in three stages: exposure, influence and engagement.^{15,16} Exposure measures the reach that the media has achieved with its current efforts, using metrics such as impressions, fans, followers, visits, views, mentions and subscribers. Influence is a look at whether the metrics are positive, neutral, or negative in sentiment; commonly the variables are “likes” and its variations. Engagement, in turn, measures how many people actually did something with the message, e.g., clicks, retweets, shares, replies, direct messages, wall posts and comments.

This paper analyzes BFMHW on the BuzzFeed website and related social media platforms (Facebook, Twitter and YouTube) using metrics of information delivery in mental health topics. We also intended to identify social media marketing strategies that may reveal important factors in effective online engagement, potentially paving the road for future online mental health interventions.

Methods

Ethics

This study was approved by the Research Ethics Committee of Hospital de Clínicas de Porto Alegre and Universidade Federal do Rio Grande do Sul.

BFMHW on the BuzzFeed website

Based on the strategies most commonly used by content media to verify the impact of publications, we extracted social media metrics from the BFMHW website¹³ on February 15th, 2017. On that date, the website had 100 updated publications related to the topic, ordered by number of BuzzFeed interactions (total number of likes, comments and shares on the BuzzFeed website), from highest to lowest. We extracted the title and total number of BuzzFeed interactions of each of the 100 posts. Then, the 20 publications with the highest number of BuzzFeed interactions were selected for a more detailed evaluation.¹⁷ These 20 posts were manually extracted from the BuzzFeed website, descriptive metrics were collected and we searched for the posts on Facebook, Twitter and YouTube to identify which ones had been shared.

The following metrics were extracted from the 20 selected posts in each social media platform: a) Facebook: shares, likes, comments and views; b) Twitter: retweets, replies and likes; c) YouTube: likes, shares, views and subscriptions (number of new subscribers gained from a particular video). We chose three social media metrics to explore, namely, exposure (presence online, views and time online), influence (likes) and engagement (comments, shares, replies and BuzzFeed interactions) (Figure 1).

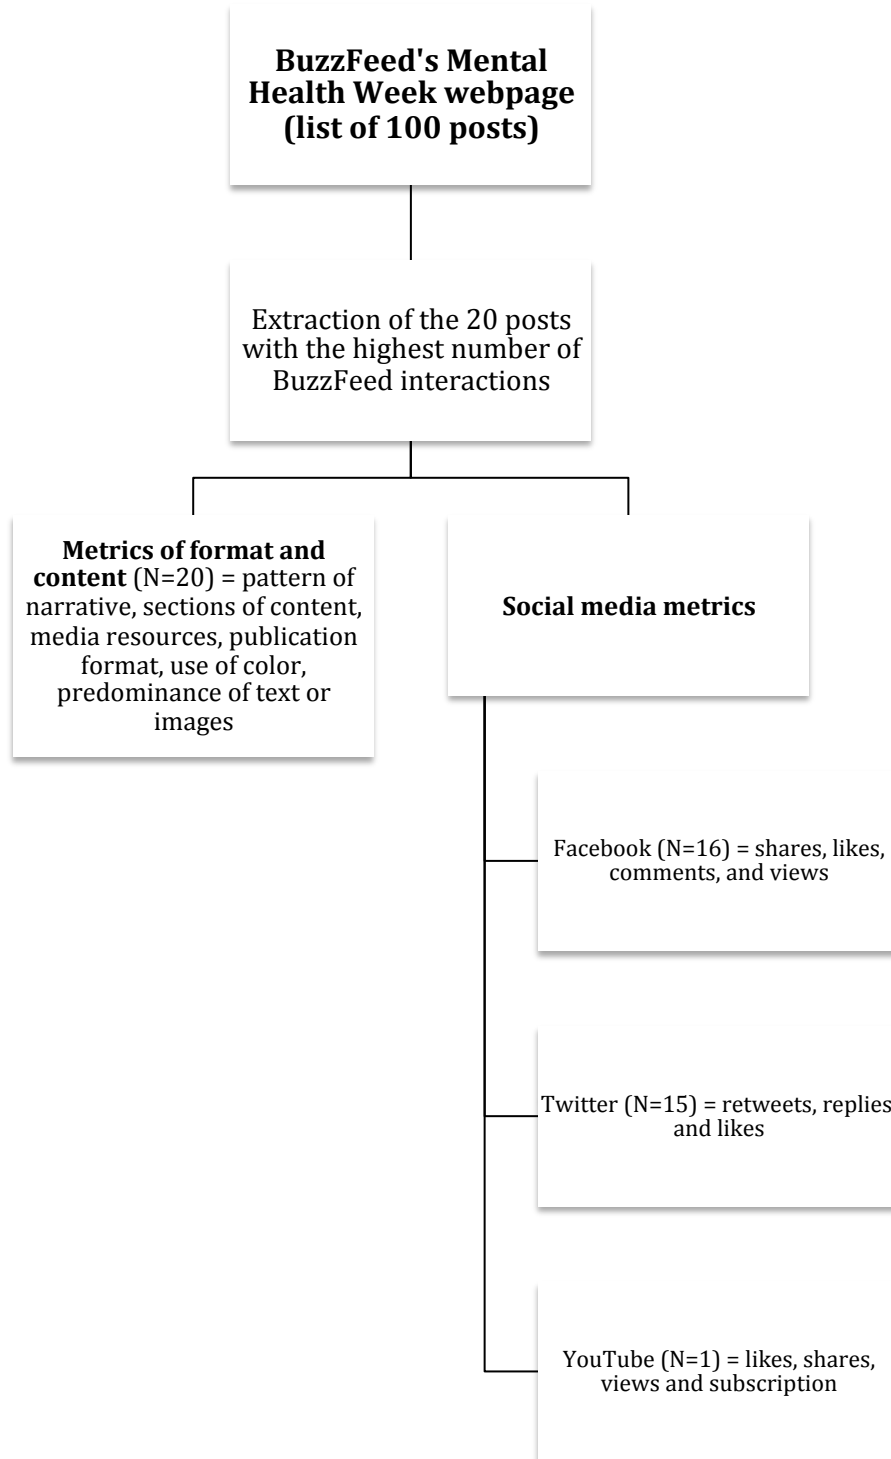


Figure 1. Selection of 20 posts from BuzzFeed's Mental Health Week webpage

BFMHW videos on YouTube

Videos are a powerful source of information. In order to check how an entertainment video delivers mental health information, we extracted data from the 41 videos available on

the BFMHW playlist created by the BuzzFeed Video profile¹⁸ (there were a total of 43, but 2 were excluded because they did not have mental health as the main topic). This part of the data collection was performed between January and April 2017. The following objective metrics were extracted from the posts on YouTube: likes, shares, views and subscription.

To check the spread of the same video through different social media platforms, we also searched Facebook and Twitter for those specific 41 posts, also between January and April 2017. The following metrics were extracted from Facebook: shares, likes, comments and views; and from Twitter: retweets, replies and likes (Figure 2).

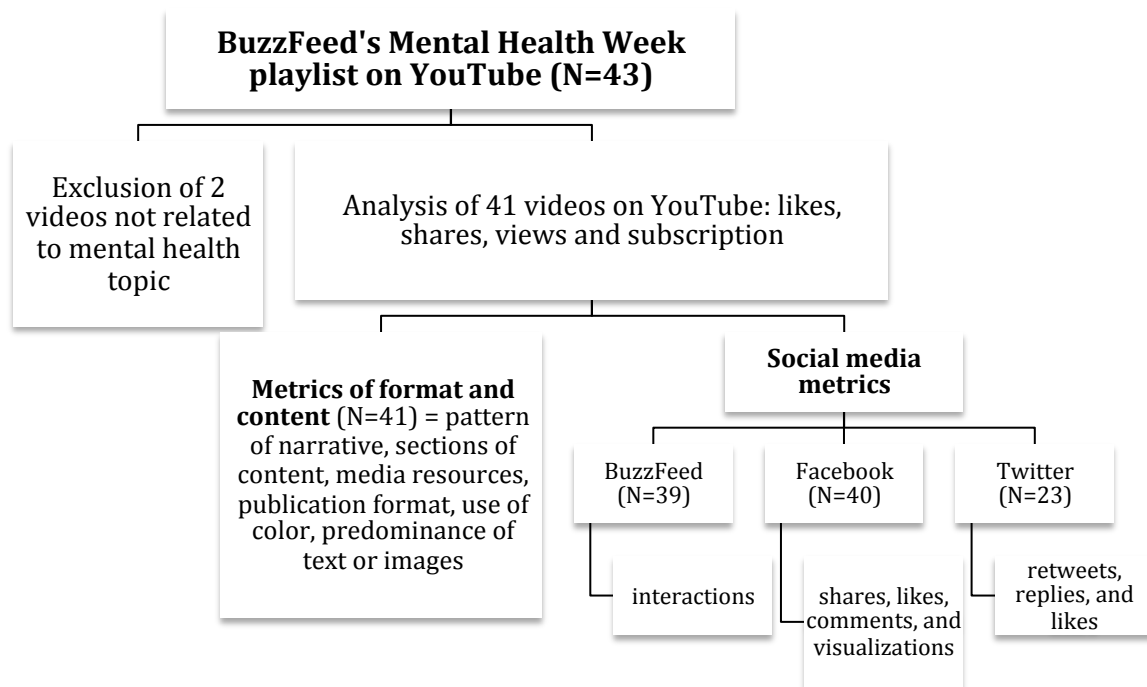


Figure 2. Selection of 41 videos available on BuzzFeed's Mental Health Week playlist on YouTube

Frequency and number of views of mental health topics in posts and videos

To assess the frequency and number of views of topics in posts and videos, we searched for 41 videos on the BFMHW YouTube page and 3 posts on the BuzzFeed website

(N=44). We excluded 17 posts for the reason that there were no available numbers of views on the website.

Metrics of format and content

In addition to social media metrics, we considered it equally important to assess extradepictive metrics by analyzing the format and content used in BuzzFeed's publications. All descriptive data were extracted as follows: a single author read or watched each post or video and arbitrarily classified their content or format considering four major groups for further examination: pattern of narrative, content, media format and publication format. Within these categories, we grouped the most frequent features as follows: pattern of narrative – self-report, graph/list, fictional, audio/image and interview; content – mixed, experience, information, humor, inspiration, pop cultural elements, tips and expression; media format – illustration, mixed media, GIFs, screenshots, animations, video and long audios; publication format – what, who, long, list and why. Given the diverse nature of contents in posts and videos, we decided to examine separately BFMHW posts on its own website and videos available on the BFMHW playlist on YouTube. Therefore, we will present the results obtained for videos and posts independently, considering the relevant categories in each case.

To assess pattern of narrative, we checked if the main story was a self-report or a graph/list. Videos were classified as either self-report/own experience or fiction (produced as a series). We further checked if the videos used only audio and self-image or if they had an interview format with a third person. To evaluate a variety of components of content, we examined the content of website posts and of YouTube videos based on the features described above. Media format was classified as animations, illustrations, GIFs, screenshots (images of self-reports online, comments and posts) or all mixed; in videos, we examined all the above plus long speeches (audio) on the topic. Finally, we assessed publication format and classified it as a list (a series of short statements generally numbered and/or written in list format), "what" (if the main idea was something being explained descriptively), "who" (if

there was a main character/persona), “why” (something being explained and justified – i.e., more analytic text with reasons included) and length (long texts or only a few images with short statements). The use of color was also rated (colored, white, or dark), as was whether it was a text or an image post.

Data analysis

The variables were analyzed using the Shapiro-Wilk normality test. All non-parametric data were expressed as medians (interquartile range) and parametric data as means (standard deviation). Subsequently, exploratory analysis of the relationship between variables was examined using Pearson and Spearman correlation coefficients. Analyses were performed using the Statistical Package for the Social Sciences (SPSS) version 19.0 for Windows, Microsoft Excel and R. All variables studied were free to access on the respective websites. Significance was set at $p < 0.05$. We used Bonferroni correction for multiple comparisons.

Results

General metrics

We analyzed the content, format and social media metrics of 20 posts and 41 videos related to BFMHW. The 20 posts were shared on the BuzzFeed website as well as on Facebook (16), Twitter (15) and YouTube (1) (Table 1/a). The 41 videos on the YouTube playlist were shared on Facebook (40), the BuzzFeed website (39) and Twitter (23) (Table 1/b).

Table 1. Social media general metrics

Samples	YouTube	BuzzFeed	Facebook	Twitter
a) BuzzFeed post	N=1	N=20	N=16	N=15
Time online (days)	458	461 (3)	459.5 (3.5)	459 (3)

No. of subscriptions	1,399	-	-	-
Video duration (seconds)	307	-	-	-
b) YouTube playlist	N=41	N=39	N=40	N=23
Time online (days)	461 (7)	463 (7)	474.5 (7)	476 (2.5)
No. of subscriptions	61 (75)	-	-	-
Video duration (seconds)	198	-	-	-

All variables are non-parametric and are described as median and interquartile range (IQR). YouTube variables for the BuzzFeed post are based on one single video.

Analyzing the materials from the BuzzFeed website, we found that the single video shared on YouTube reached 1,399 subscribers. In contrast, analysis of the 41 videos collected directly from YouTube revealed a median number of subscriptions as low as 61.

Median time online (posts' exposure online) was 461 days on BuzzFeed's website and 458 days on YouTube; Facebook and Twitter showed 459.5 and 459 days, respectively. Similarly, the playlist on YouTube showed a median time online of 476 days on Twitter, followed by 474.5 on Facebook, 463 on BuzzFeed and 461 days on YouTube. Videos from the playlist on YouTube had a mean duration of 198 seconds (Table 1/b).

Frequency and number of views of mental health topics in posts and videos

At first, we checked the frequency of topics, and treatment was the one most frequently found, accounting for 31.82% of the items (14 posts and videos – 7 about therapy and 7 about coping). The number of views of treatment-related posts corresponded to 35.59% of the total of views of 14 videos/posts.

Two groups came second in rank for topic frequency, namely anxiety disorder and suicide (15.91% of the topics each); anxiety disorder included 4 videos about anxiety and 3 about post-traumatic stress disorder (PTSD); suicide had a total of 7 videos and posts. However, differently from frequency, the number of views of posts/videos on anxiety disorder (16.46%) and suicide (23.14%) revealed different interests of the audience. Depression

(frequency of 11.37% of videos available and 7.57% of number of views) had a total of 5 videos, including depression (4 videos) and self-harm (1 video). Also with 11.37% of topic frequency, stigma had a total of 5 videos, while its number of views corresponded to 4.94% of the total number of accesses. Topics focusing on attention-deficit/hyperactivity disorder (ADHD) accounted for 9.1% of the frequency, with 4 videos. Likewise, the number of views in this group accounted for 9.74% of accesses. Finally, 2 videos (frequency of 4.55% of videos available and 2.56% of total number of views) were included in the addiction category: 1 about addiction and 1 about eating disorder (Figure 3).




Figure 3. Comparison of frequency and views of posts from BuzzFeed's Mental Health Week (BFMHW) website and videos from the BFMHW YouTube webpage. A. Topic frequency in 3 posts from the BFMHW website and 41 videos from the BFMHW YouTube webpage: a. Treatment 31.82%, total of 14 videos/posts, grouped as therapy (2 posts and 5 videos) and coping (7 videos); **b. Anxiety disorder 15.91%**, total of 7 videos, grouped as anxiety (3 videos) and post-traumatic stress disorder (PTSD) (4 videos); **c. Suicide 15.91%**, total of 7 videos/posts (6 videos and 1 post); **d. Depression 11.37%**, total of 5 videos, grouped as depression (4 videos) and self-harm (1 video); **e. Stigma 11.37%**, total of 5 videos; **f. ADHD 9.1%**, total of 4 videos; **g. Addiction 4.55%**, total of 2 videos, grouped as eating disorder (1 video) and addiction (1 video). **B. Views of 3 posts from the BFMHW website and 41 videos from the BFMHW YouTube page: a. Treatment 35.59% (15'237'333 views)**, total views of 14 videos/posts, grouped as 5 videos about therapy (8'506'635), 1 post also about therapy (1'969'572) and 7 videos about coping (4'761'126); **b. Anxiety disorder 16.46% (7'042'139 views)**, total views of 7 videos, grouped as 3 about anxiety (2'043'339) and 4 about PTSD (4'998'800); **c. Suicide 23.14% (9'900'950 views)**, total views of 6 videos (8'827'307) and 1 post (1'073'643); **d. Depression 7.57% (3'238'649**

views), total views of 5 videos, grouped as 4 about depression (2'029'168) and 1 about self-harm (1'209'481); **e. Stigma 4.94% (2'111'542 views)**, total views of 5 videos (4'168'390); **f. ADHD 9.74% (4'168'390 views)**, total views of 4 videos; **g. Addiction 2.56% (1'094'963 views)**, total views of 2 videos, grouped as eating disorder (711'287) and addiction (383'676).

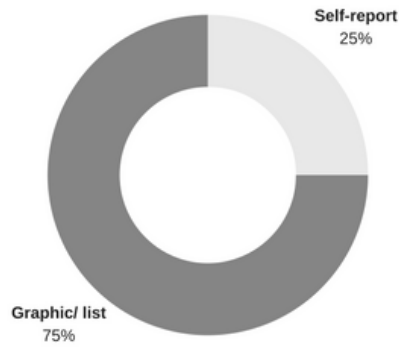
Metrics of format and content

Format and content were evaluated with descriptive elements and are expressed here as percentages considering the 20 posts extracted from the BFMHW website and the 41 videos available at the BFMHW playlist on YouTube.

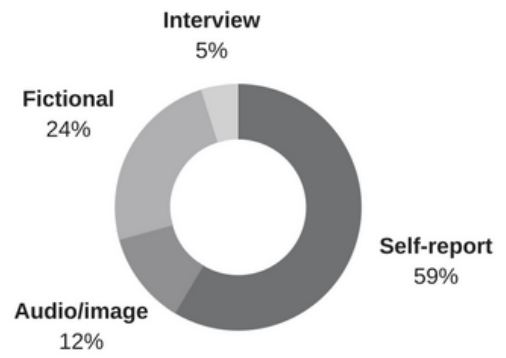
Pattern of narrative

Of the website posts, 75% used graphs/lists as the pattern of narrative and only 25% used self-reports/experience as main stories. Among the videos, an array of different narrative elements were found, with the majority featuring self-reports/experience (58%). Of these, 75% were real-life self-reports and the remaining 25% were interpreted by actors from the BuzzFeed team. Fictional stories accounted for 24% of the videos; of these, 60% were short interpretations and 40% were web series. We also found that 12% of the videos used audio/images; only 5% were interviews (graphs A1 and A2 in Figure 4).


A1. Narrative (website)




A2. Narrative (videos on YouTube)



B1. Content (website)



B2. Content (videos on Youtube)



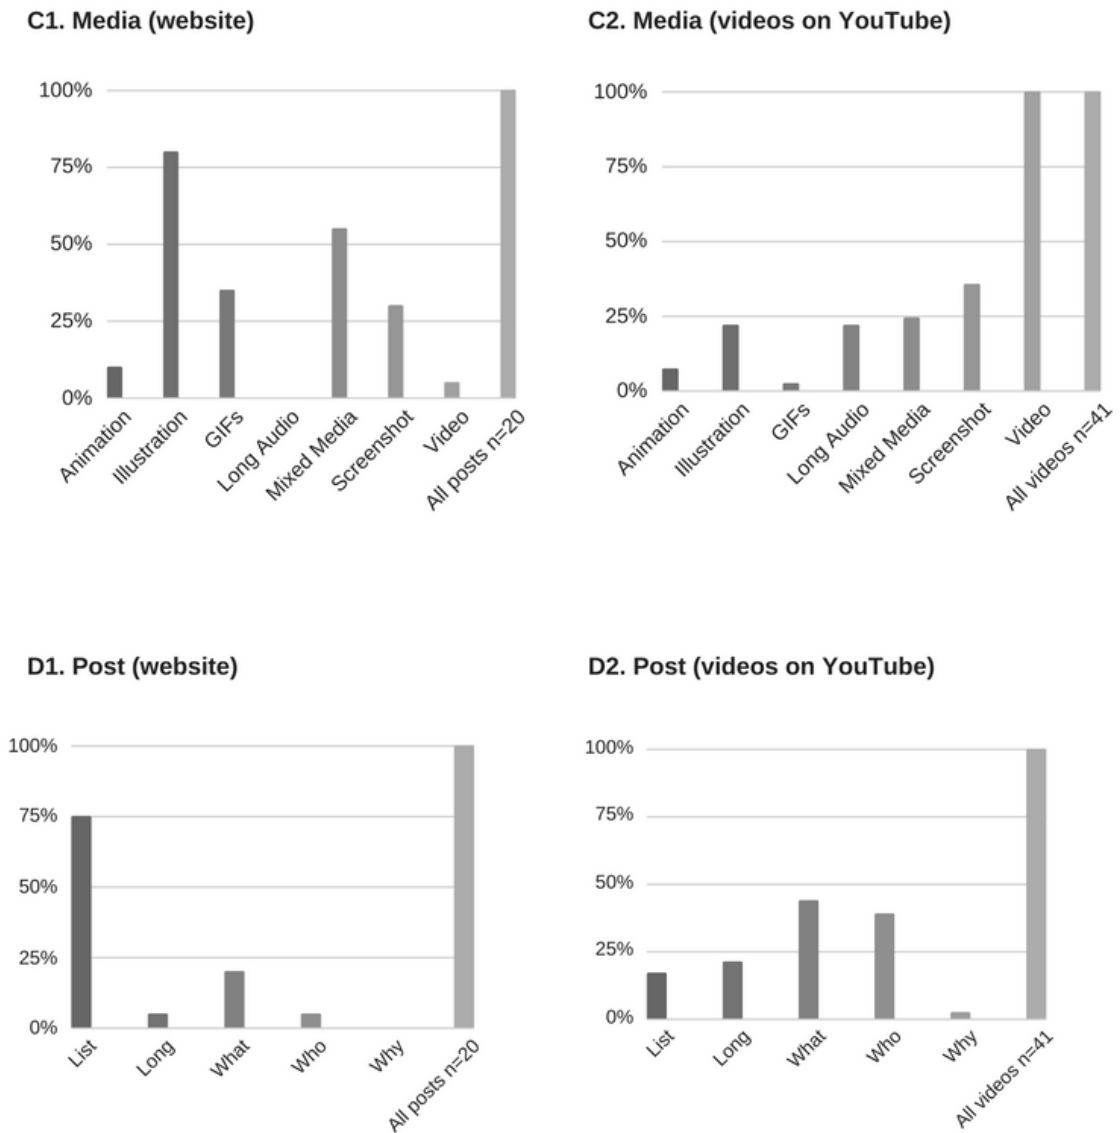


Figure 4. Metrics of format and content in BuzzFeed’s Mental Health Week (BFMHW) posts and videos. 1) Analysis of 20 posts from the BFMHW website: A1. Patterns of narrative: self-report/experience (25%), graph/list (75%); **B1. Content:** mixed (85%), experience (85%), information (40%), humor (35%), inspiration (35%), pop cultural elements (25%), tips (15%), expression (5%); **C1. Media format:** illustration (80%), mixed media (55%), GIFs (35%), screenshots (30%), animations (10%), video (5%); **D1. Publication format:** list (75%), what (20%), long (5%), who (5%). **2) Analysis of 41 videos from the BFMHW playlist on YouTube: A2. Patterns of narrative:** self-report/experience (58.53%), fictional (24.39%), audio/image (12.19%), interview (4.88%); **B2. Content:** experience (80.49%), mixed (78.05%), expression (65.85%), information (43.9%), humor (31.7%), inspiration (14.63%), tips (7.32); **C2. Media format:** screenshots (35.61%), mixed media (24.39%), long audios (21.95%), illustrations (21.95%), animations (7.32%), GIF (2.44%); **D2. Publication format:** what (43.9%), who (39.02%), long (21.20%), list (17.07%), why (2.44%).

Content

In the analysis of content, experience and mixed content were the most common categories, accounting for 85% of the website posts. Among the YouTube videos, the experience category was identified in 81% and mixed content in 78% (graphs B1 and B2 in Figure 4). BuzzFeed's website posts also had information as content in 40%, humor and inspiration in 35% and pop cultural elements in 25%. Tips and expression were the least common types of content found, accounting for only 15% of the videos and 5% of the posts, respectively. We observed that information, humor and tips showed similar trends in both posts and videos, as opposed to expression and inspiration, which demonstrated contrary trends.

Media format

Media resource evaluation revealed that most website posts used illustrations (80%), whereas most YouTube videos used screenshots (75%), i.e., images of self-reports online. These trends tended to be opposite in website posts vs. YouTube videos, i.e., while illustrations ranked first among website posts, they were 4th among YouTube videos (21%) and while screenshots ranked first among videos, they appeared in 4th for posts (30%). Mixed media (use of more than one kind of media resource in the same post/video), in turn, ranked second in both posts (55%) and videos (24%). We found that website posts used GIFs in 35% of cases; among the videos, long audios accounted for a slightly smaller number (22%). Also, there was no contrasted presence of color in 59% of the videos from BuzzFeed's playlist on YouTube. The least common media resources were animations (10%) and videos (5%) among BuzzFeed's website posts and again animations (7%) and GIFs (2%) in the YouTube videos (graphs C1 and C2 in Figure 4).

Publication format

In this analysis, we found that 75% of the website posts used lists as their main element, in contrast with YouTube videos, where lists accounted for a much lower

percentage (17%). Videos also tended to show the “what” format, with 44%, compared to 20% of the posts. The “who” approach ranked second in videos (39%) and last in website posts (5%). Long text format was found in only 5% of the posts and long audios in 21% of the videos. Finally, the “why” format was present in only 2% of the videos (graphs D1 and D2 in Figure 4). According to these data, 73% of the YouTube videos used a persona/character.

Social media metrics

Exposure

Some exposure variables were presented above (time online and objective metrics of format and content).

Views. When we looked at posts from the BFMHW website, only 3 had publicly available data, with a median of 1,073,643 views (posts); the single post that was shared on YouTube had 3,892,643 views (Table 2). The Facebook sample of videos available on the BFMHW playlist on YouTube was slightly smaller (Facebook had 36 videos and YouTube 40) than the original full sample of 41 videos on YouTube. Despite this difference, the median rates of views for the videos were slightly larger on Facebook (36 videos), with 780,945, vs. 634,038 on YouTube (41 videos) (Table 3).

Table 2. Social media metrics: BuzzFeed’s Mental Health Week posts on own website, median (IQR)

Media metrics	BuzzFeed	YouTube	Facebook	Twitter
BuzzFeed posts	N=20	N=1	N=16	N=15
Total interactions	229 (63.75)	170,237	1,203 (2,890.5)	392 (495)
Views	1,073,643 (172,770; n=3)	3,892,643	-	-
Shares/retweets	-	19,178	285 (849.25)	112 (135.5)
Likes/favorite	-	139,580	848 (2,002.5)	276 (356.5)

Comments/replies	-	9,687	40.5 (72.25)	2 (5)
Time online (days)	461 (3)	458	-	-
Subscriptions	-	1,399	-	-

Presence. We determined which posts and videos extracted from both the BFMHW website and the BFMHW playlist on YouTube were also found in other social media platforms. Videos were more likely to be found in different social media sites (54%, 22 of 41 videos were found at all social media sites studied), while website posts had only 5% of the sample with this broad distribution (1 of 20 posts). Further, 42% of the videos (17 of 41) were present on two social media sites, compared to 65% of website posts (13 of 20). Finally, 15% (3/20) of website posts were not distributed to any social media sites.

Influence

Likes. The single video available among the posts on BuzzFeed’s website that was also shared on YouTube had the highest median of 139,580 likes and favorites on YouTube, compared to 848 and 276 interactions found on Facebook and Twitter, respectively, despite the greater sample size in the two latter platforms (16 and 15 posts, respectively) (Table 2). The material extracted from the YouTube playlist showed a higher median of likes and favorites (17,786) than the items shared on Facebook (8,463) and Twitter (226) (Table 3).

Table 3. Social media metrics: BuzzFeed’s Mental Health Week playlist on YouTube, median (IQR)

Media metrics	YouTube	Facebook	Twitter	BuzzFeed
YouTube playlist	N=41	N=40	N=23	N=39
Total interactions	20,161 (24,293)	12,773 (21,241.25)	349 (459.5)	45 (53.5)
Views	634,038	780,945	-	-

	(572,579)	(833,744.75; n=36)		
Shares/retweets	1,203 (2,307)	4,510 (10,207)	92 (135)	-
Likes/favorite	17,786 (19,504)	8,463 (12,707)	226 (330)	-
Comments/replies	1,536 (2,250)	449.5 (629.5)	2 (5.5)	-
Time online (days)	461 (7)	474.5 (7)	476 (2.5)	463 (7)
Subscriptions	61 (75)	-	-	-

Engagement

Total interactions. The posts on the BFMHW website showed a median of 229 total interactions. The single post shared on YouTube showed a much higher median, of 170,237 interactions. In addition, Facebook and Twitter showed 1,203 and 392 median interactions, respectively (Table 2). The videos extracted from YouTube, in turn, revealed a median of 20,161 total interactions and 12,773 on Facebook. However, these videos showed a much smaller median number of total interactions on Twitter and BuzzFeed, with 349 and 45, respectively (Table 3).

Shares and retweets. When we looked at posts shared on social media from the sample taken from the BFMHW website, the median number of shares and retweets was much higher on YouTube (19,178) than on Facebook (285) and Twitter (112) (Table 2). However, when we looked at the sample of videos from the BFMHW playlist on YouTube, the median of shares and retweets was higher on Facebook (4,510) than on YouTube (1,203). Finally, Twitter showed the lowest number of interactions (92) (Table 3).

Comments, replies and BuzzFeed interactions. Regarding comments, replies and BuzzFeed interactions in the sample of posts on the BFMHW website, a median of 9,687 actions was found on YouTube, vs. 40.5 on Facebook and only 2 on Twitter (Table 2). Once again, YouTube had a much higher median number of comments and replies on the BFMHW YouTube playlist (1,536). Facebook had a median of 449.5 actions, and Twitter, only 2 replies (Table 3).

Pearson and Spearman correlations

Analysis of the relationship between variables revealed a correlation between views on YouTube and total interactions on Facebook (0.66, $p < 0.001$), shares on Facebook (0.71, $p < 0.001$), BuzzFeed interactions (0.56, $p < 0.001$) and total interactions on YouTube (0.75, $p < 0.001$). There was no correlation between views on YouTube and time online on YouTube (0.09, $p = 0.568$). Also, there were no significant correlations among any of the following variables on Facebook: time online, likes, comments, views; on YouTube: views, shares, likes and total number of likes, comments, subscriptions; on BuzzFeed: time online; or on Twitter: time online, shares, likes, replies, retweets, total number of interactions. We used Bonferroni correction for multiple comparisons; therefore we used a significance level of 0.002.

Discussion

This study was conducted to analyze online interactions on the BFMHW website and related social media platforms (Facebook, Twitter and YouTube) using metrics of information delivery in mental health topics. The analysis revealed important data about the promotion of mental health online.

In this study, Twitter showed lower engagement rates when compared to Facebook, YouTube and website, which would be expected if we consider the global lower activity rates on Twitter in general.¹⁹ Also, our results suggest that videos on YouTube may be an important information channel, as they showed the strongest association with engagement variables (shares, interactions, BuzzFeed interactions), including activity and engagement on other medias such as Facebook and website. The results also showed that audience engagement is associated with the number of medias in which the content is published, rather than with time available online. Indeed, videos shared also on Facebook were viewed more frequently than those distributed via YouTube only. This finding supports the authors'

hypothesis that videos are an important information channel, particularly when associated with broad content distribution.

We could explore, in future studies, if a greater amount of detailed information available online about types of treatment and their availability would enhance earlier help-seeking and reduce stigma about the treatment itself, instead of focusing only on diagnosis and symptoms. We could hypothesize that patients may recognize that they are not well, even though they may not be able to name their condition. However, if they are not afraid of treatment and if they know what to expect and how treatment works in detail, they may be more likely to seek help. In agreement with that, our results showed that the most popular video was a comedy about fear of treatment.²⁰

Of 44 posts and videos, the majority addressed treatment, followed by anxiety disorder and suicide. When analyzed according to number of views, the 44 posts and videos were about treatment, suicide and anxiety. The content of the 44 videos and posts was similar to the distribution of the audience's interest, assessed by number of views. In this sense, the high rates of interest in suicide and treatment are noteworthy. Among the contents examined, it seems that suicide information may be slightly falling behind audience demand.

Given the link between the use of technology and the accessibility of information, the case study examined in this article may contribute to future development of online mental health interventions and initiatives. We chose the case of BFMHW based on its characteristics as a well-known, successful, highly accessed online initiative. From the metrics analyzed in the BFMHW website, our results suggest that the higher the number of social media websites in which a post is shared, the higher the rates of visualization. The present results should be interpreted in light of the fact that we chose a website with adequate content about mental health. In this sense, it is important to highlight that evaluating how intrinsic content quality influences metrics was not within the scope of this study – rather, our aim was to analyze the pattern of information distribution online. We can say that, in this specific case of appropriate content, exposure was correlated with engagement; whether the same would occur with posts with low-quality content remains

unknown. Nevertheless, among social media metrics, engagement rates could be used as a measure of the effective delivery of key messages, as it takes into account the person's actions as a measure of actual contact with the online content.²¹ In this sense, we suggest that mental health initiatives online should consider video format and publication in more than one media channel.

Despite the comprehensive quantitative data collected on social media metrics, we could not qualitatively examine the format and content of the posts and videos related to BFMHW. Rather, we created a categorical analysis with descriptive data of format and content metrics. We conducted this exploratory categorical analysis of the content of posts and videos in order to describe the sample rather than draw conclusions about the posts' contents. Despite sample size limitations (20 posts and 41 videos), format and content analysis revealed some interesting trends. Of the posts collected from BuzzFeed's website, it is interesting to note that there were specific materials for each media, i.e., lists in 75% and illustrations in 80% of the website posts and screenshots in 76% of the videos. Videos included most frequently a sequence of screenshots of people's opinions and self-report narrative. In content analysis, a similar trend was observed in using people's own experience (81% of videos and 85% of posts) and mixed types of content (85% of posts and 78% of videos) – these were the most prevalent content elements. Being aware of these characteristics of format and content could help mental health professionals produce better content focused on larger online audiences. Karasouli & Adams,²² for example, suggest that the development of effective mental health self-management e-resources have the potential to become a widely effective intervention in mental health.

This study has sample limitations (size and singular nature) and therefore should be considered exploratory with regard to format and content findings. However, with a larger sample of social media metrics, analyses with two groups could be run to check which metrics of format and content are more likely to influence engagement metrics, for example. Further studies are necessary to check if the parameters we used for 'engagement' online

(activity associated with content) will ultimately translate into attitudes offline, such as effective help-seeking and treatment adherence.

This paper identified social media marketing strategies that could be used to promote mental health and reduce the stigma in future online interventions. The case study of the successful BFMHW initiative suggests that information may be more effective in reaching the audience if delivered in video format, if shared in more than one media, if it includes personal experience and some humor in content and more detailed information about types and format of treatment. To the best of our knowledge, this is the first article to analyze BFMHW content collecting material from its own webpage and also from social media. The study of this case can shed some light on successful strategies when using online methods to engage people in online interventions and help expand the literature on the promotion of mental health online.

Acknowledgments

This work was supported by Fundo de Incentivo a Pesquisa e Eventos – Hospital de Clínicas de Porto Alegre and by the National Science and Technology Institute for Translational Medicine, with the financial support of Coordenação de Aperfeiçoamento de Pessoal de Nível Superior and Conselho Nacional de Desenvolvimento Científico e Tecnológico. The funders had no role in study design, data collection and analysis, decision to publish, or in manuscript preparation. MB was supported by a Senior Principal Research Fellowship from the National Health and Medical Research Council (NHMRC; 1059660).

References

1. Pew Research Center. Internet seen as positive influence on education but negative influence on morality in emerging and developing nations. Washington: Pew Research Center; 2015. [cited 2017 September 13]. <http://www.pewglobal.org/files/2015/03/Pew-Research-Center-Technology-Report-FINAL-March-19-20151.pdf>
2. Colom F, Vieta E, Sánchez-Moreno J, Palomino-Otiniano R, Reinares M, Goikolea JM, et al. Group psychoeducation for stabilised bipolar disorders: 5-year outcome of a randomised clinical trial. *Br J Psychiatry*. 2009;194:260-5.
3. Reinares M, Colom F, Rosa AR, Bonnín CM, Franco C, Solé B, et al. The impact of staging bipolar disorder on treatment outcome of family psychoeducation. *J Affect Disord*. 2010;123:81-6.
4. Reavley NJ, Jorm AF. Recognition of mental disorders and beliefs about treatment and outcome: findings from an Australian national survey of mental health literacy and stigma. *Aust N Z J Psychiatry*. 2011;45:947-56.
5. Mackey TK, Schoenfeld VJ. Going "social" to access experimental and potentially life-saving treatment: an assessment of the policy and online patient advocacy environment for expanded access. *BMC Med*. 2016;14:17.
6. Yamaguchi S, Mino Y, Uddin S. Strategies and future attempts to reduce stigmatization and increase awareness of mental health problems among young people: a narrative review of educational interventions. *Psychiatry Clin Neurosci*. 2011;65:405-15.
7. Cox-George C. The changing face(book) of psychiatry: can we justify "following" patients' social media activity? *BJPsych Bull*. 2015;39:283-4.
8. Crutzen R, Ruiters RA, de Vries NK. Can interest and enjoyment help to increase use of Internet-delivered interventions? *Psychol Health*. 2014;29:1227-44.
9. Betton V, Borschmann R, Docherty M, Coleman S, Brown M, Henderson C. The role of social media in reducing stigma and discrimination. *Br J Psychiatry*. 2015;206:443-4.

10. Christensen H, Griffiths KM, Farrer L. Adherence in internet interventions for anxiety and depression. *J Med Internet Res*. 2009;11:e13.
11. Ziebland S, Wyke S. Health and illness in a connected world: how might sharing experiences on the Internet affect people's health? *Milbank Q*. 2012;90:219-49.
12. Tandoc Jr EC, Jenkins J. The Buzzfeedication of journalism? How traditional news organizations are talking about a new entrant to the journalistic field will surprise you! *Journalism*. 2015;18:482-500.
13. BuzzFeed. Mental Health Week [website]. [cited 14 June 2017]. <https://www.buzzfeed.com/mentalhealthweek>
14. Hubspot Academy. Understanding content marketing (content marketing certification – class transcript). [cited 2017 September 13]. <https://cdn2.hubspot.net/hub/202647/file-43774095-pdf/docs/scribewisewhitepaper.beginnersguide.pdf>
15. Kelly N. Measuring social media for brand awareness. HootSuite – Social Media Dashboard. 2011. [cited 2017 September 13]. http://static.hootsuite.com/White_Paper/WhitePaper_03_HS_FullFrontalROI_Brand_Awareness.pdf
16. Neiger BL, Thackeray R, Van Wagenen SA, Hanson CL, West JH, Barnes MD, et al. Use of social media in health promotion: purposes, key performance indicators, and evaluation metrics. *Health Promot Pract*. 2012;13:159-64.
17. BuzzFeed. Mental Health Week [website]. [cited 14 June 2017]. <http://bzfd.it/2saaReg>
18. YouTube. Mental Health Week [playlist]. [cited 14 June 2017]. <http://bit.ly/2rrbBi8>
19. Statista. Worldwide revenue of Twitter from 2010 to 2017 (in million U.S. dollars) [website]. [cited 14 June 2017]. <https://www.statista.com/statistics/204211/worldwide-twitter-revenue/>
20. YouTube. The Try Guys try therapy [Internet]. The Try Guys S05 E03. BuzzFeed Video. [cited 2015 Dec 13]. <https://www.youtube.com/watch?v=ystGdduzG64&list=PL5vtqDuUM1DltRct7SkzxdQa2ZQC0EEFh&index=1>

21. Kelly L, Jenkinson C, Ziebland S. Measuring the effects of online health information for patients: item generation for an e-health impact questionnaire. *Patient Educ Couns.* 2013;93:433-8.
22. Karasouli E, Adams A. Assessing the evidence for e-resources for mental health self-management: a systematic literature review. *JMIR Ment Health.* 2014;1:e3.

6. ARTIGO 2

O segundo artigo é o principal achado deste trabalho, é o resultado de um projeto realizado no Hospital de Clínicas de Porto Alegre utilizando ferramentas desenvolvidas em conjunto com outros grupos de pesquisa da Universidade Federal do Rio de Janeiro e Universidade Federal do Rio Grande do Norte. Intitulado “O Impacto dos Transtornos Mentais no Uso de Internet e Redes Sociais *On-Line*”, este projeto passou por diversas fases e exigiu profissionais de diferentes áreas atuando em sua concepção. Em sua versão final, este estudo resultou no artigo intitulado "*Digital phenotype of bipolar depression: a machine-learning approach based on Facebook data*", com submissão programada para o fim de 2018.

Digital phenotype of bipolar depression: a machine-learning approach based on Facebook data

Short Title: detection of Bipolar depression on Facebook

Digital phenotype of bipolar depression: a machine-learning approach based on Facebook data

Short Title: Detection of Bipolar depression on Facebook

Martini TC¹, da Ponte FDR¹, Hasse de Souza M¹, Prates-Baldez D¹, Bucker J¹, Moulin T², Cavalcante-Passos I^{1,3}, Kieling C³, Amaral OB², Kauer-Sant'Anna M^{1,3}.

¹ Programa de Pós-Graduação em Psiquiatria e Ciências do Comportamento, Laboratório de Psiquiatria Molecular, Hospital de Clínicas de Porto Alegre, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, Brazil.

² Instituto de Bioquímica Médica Leopoldo de Meis, Universidade Federal do Rio de Janeiro.

³ Departamento de Psiquiatria e Medicina Legal, Hospital de Clínicas de Porto Alegre, UFRGS, Porto Alegre, RS, Brazil.

RESUMO (tradução da autora)

A maior dificuldade do transtorno bipolar está associada a sintomas depressivos persistentes e múltiplos episódios. Vários estudos propuseram que o conteúdo e a atividade da mídia social podem ajudar a detectar transtornos mentais. A maioria das evidências anteriores vem de estudos de comportamento de mídias sociais em amostras com depressão unipolar; existe pouca informação disponível

sobre episódios depressivos bipolares. Alguns autores propuseram recentemente que o transtorno mental pode afetar o comportamento nas mídias sociais, o que poderia ser entendido como um fenótipo digital. Para estudar como episódios depressivos bipolares podem estar associados a um padrão único de uso e conteúdo de mídias sociais, realizamos um estudo transversal, com uma média de 12 meses de extração retrospectiva de dados do Facebook e examinamos o modelo de associação com episódios de depressão durante o mesmo intervalo de tempo. Um total de 33 pacientes com BD I ou II, de acordo com o DSM-5, foram recrutados. Usamos a análise semântica (LIWC) de palavras afetivas, variáveis sociodemográficas em uma abordagem de aprendizado de máquina para testar a precisão na predição de episódios depressivos. Descobrimos que o conteúdo semântico em um modelo também incluía sexo, idade e escolaridade, uma AUC de 86,7; enquanto o modelo incluindo apenas a análise semântica das palavras afetivas mostrou uma AUC de 53.5. Com base nisso, sugerimos que a análise linguística do conteúdo do Facebook pode valer a pena ser incluída em futuros modelos preditivos de depressão, mas deve estar associada a outras variáveis para aumentar a precisão do modelo. Além disso, os modelos mostraram um valor preditivo positivo muito maior e um valor preditivo negativo mais baixo, sugerindo que essa abordagem pode ser mais adequada para fins de triagem do que para o diagnóstico, como esperado. Esta evidência exploratória pode contribuir para o desenvolvimento de futuras calculadoras de risco e ferramentas de alerta para a detecção precoce de episódios depressivos em TB.

**Digital phenotype of bipolar depression:
a machine-learning approach based on Facebook data**

Short Title: detection of Bipolar depression on Facebook

Martini TC¹, da Ponte FDR¹, Hasse de Souza M¹, Prates-Baldez D¹, Bucker J¹, Moulin T², Cavalcante-Passos I^{1,3}, Kieling C³, Amaral OB², Kauer-Sant'Anna M^{1,3}.

1 Programa de Pós-Graduação em Psiquiatria e Ciências do Comportamento, Laboratório de Psiquiatria Molecular, Hospital de Clínicas de Porto Alegre, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, Brazil.

2 Instituto de Bioquímica Médica Leopoldo de Meis, Universidade Federal do Rio de Janeiro.

3 Departamento de Psiquiatria e Medicina Legal, Hospital de Clínicas de Porto Alegre, UFRGS, Porto Alegre, RS, Brazil.

Corresponding author:

Thaís Cunha Martini

Laboratório de Psiquiatria Molecular – Hospital de Clínicas de Porto Alegre

Universidade Federal do Rio Grande do Sul

Rua Ramiro Barcelos, 2350

Tel.: +55 51 33598845

E-mail: thaismartini1@gmail.com

Sources of support: Fundo de Incentivo a Pesquisa e Eventos – Hospital de Clínicas de Porto Alegre; National Science and Technology Institute for Translational Medicine (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior and Conselho Nacional de Desenvolvimento Científico e Tecnológico).

Conflict of interest declaration: None.

Word count: 3,140

Number of tables and figures: 1 table and 3 figures

Keywords:

LIWC; Linguistic analysis; Machine learning; Social media; Social networking sites; Bipolar Disorder; Mental health; depression; digital phenotype.

Abstract:

The highest burden of BD is associated with persistent depressive symptoms and multiple episodes. Several studies have proposed that social media content and activity may help to detect mental disorder. Most of the previous evidence comes

from studies of social media behavior in samples with unipolar depression; less information is available about bipolar depressive episodes. Some authors have recently proposed that mental disorder may affect behavior in social media, which could be understood as a digital phenotype. To study how bipolar depressive episodes may be associated with a unique pattern of social media usage and content, we carried out a cross-sectional study, with a mean of 12 months of longitudinal retrospective data extraction from Facebook and examined the model of association with depressive episodes during the same time interval. A total of 33 patients with BD I or II, according to DSM-5, were recruited. We used semantic analysis (LIWC) of affective words, sociodemographic variables in a machine learning approach to test the accuracy to predict depressive episodes. We found that semantic content in a model also included sex, age and education dispensed an AUC of 86.7; while the model including only the semantic analysis of affective words showed an AUC of 53.5. Based on this, we suggest that linguistic analysis of Facebook content may be worth to be included in future predictive models of depression, but may be associated with other variables to increase the accuracy of the model. Also, the models showed a much higher positive predictive value, and lower negative predictive value, suggesting this approach may be more suitable for screening purposes than for diagnosis, as expected. This exploratory evidence may contribute to the development of future risk calculators and alert tools for early detection of depressive episodes in BD.

1. Introduction

Mental illnesses can cause severe changes in the lives of people with these diagnoses. There are modifications of behavior, mood, thinking which might influence personal (Zubieta JK et al., 2001), professional and social relationships (Kauer-Sant'anna M et al., 2009), affecting the quality of life (Dean BB, Gerner D & Gerner RH, 2004). Bipolar disorder (BD) is a mental illness characterized by mood swings that affect an individual ability to execute day-to-day tasks (NIMH, online, 2018). In fact, people with BD suffer from depression crisis much more often than mania (Bopp JM et al., 2010). The percentage adults with BD who have serious functional

impairment is the highest among mood disorders (82.9%), most of it associated with depressive episodes (Kessler et al., 2005). These deficits increase during the acute phases of the illness and worsen over its long-term course (Cardoso T et al., 2015).

To cope with the difficulties caused by BD, it is natural for people to search for help wherever it is available, and social media could play a role in this sense (Martini TC et al., 2018). Facebook, currently the most used social networking site (SNS) in the world, had an average of 1.4 billion daily active on December 2017 (Facebook Newsroom World, accessed Apr-20-2018), with 82 million active users in Brazil on November 2016 (Facebook Newsroom Brazil, accessed Apr-20-2018). Social networks influence decisions concerning mental health (Karasouli E & Adams A, 2014) and people increasingly rely on both online and offline networks to get support and relief, consequently generating extensive data records of their behavior and mood states (Shen G et al., 2017). As a result of the high engagement of social media users, studies linking SNS and psychological information about attitudes and behaviors have been on the rise (Young SD, 2014). Digital phenotype is the term used for describing the approach to measure behavior, cognition and mood from smartphones sensors (Insel TR, 2017; Jain SH et al., 2015).

It is noteworthy to highlight that information posted on social networks have an abundance of semantic content, which can reveal myriad insights about its users. Automated vocabulary analysis can predict traits such as gender, age, and personality of users with remarkable accuracy (Schwartz et al., 2012; Park et al., 2014). The usefulness of such information in psychiatry is evident since social networks can act as a window to understand complex processes such as mood swings in bipolar disorder. Both the intensity of SNS use and the content produced by

patients might correlate with mood alterations, offering the possibility of early detection and follow-up of these changes.

Several studies have proposed the use of social media for the detection of mental disorders. Nguyen et al. (2017) found that psycholinguistic features extracted from social media, using Linguistic Inquiry and Word Count (LIWC) and machine learning analyses, can provide insights into the ways depressed people interact and communicate about their illness to others. This group also found that features such as affect, written content and writing style are expressed differently between depression communities and other online communities (Nguyen et al., 2014). Another study suggests that language processing and machine learning may allow the prospect of large-scale screening of social media (Guntuku SC et al., 2017).

Social media markers have also been used to identify specific linguistic differences between people with schizophrenia and controls (Birnbaum ML et al., 2017). Choudhury et al. (2013) analyzed behavioral information (through social media posts), building a statistical classifier estimating the risk of depression before the reported onset. Researchers conducted some studies on Twitter: Birjali M et al. (2017) found this platform could be used to analyze online depression feeling; Braithwaite et al. (2016) found people with high suicidal risk could be easily differentiated from those who are not on the basis of Twitter activity and Shen G et al. (2017) proposed a multimodal depressive dictionary learning model to detect the depressed users on Twitter.

However, fewer studies chose Facebook as their primary media to harvest people's data online to detect psychiatric outcomes. Settani M & Marengo D (2015) showed that users with higher levels of depression and anxiety expressed negative emotions on Facebook more frequently. Although researchers found Facebook posts

had noisy data, a study had success in predicting depression using Facebook, LIWC and machine learning tools (Nguyen T, Armstrong W, Shrivastava A, online).

In this study, we investigate whether metrics of quantitative Facebook use or analysis of published content in adults with Bipolar Disorder correlates with mood rated with face-to-face validated retrospective scales. If we find such correlations, it may provide a basis for additional future tool using social media data and behavior to monitor or predict mood swings in BD.

2. Methods

2.1. Ethics

The study protocol was approved by the Research Ethics Committee of Hospital de Clínicas de Porto Alegre, and Universidade Federal do Rio Grande do Sul, and this investigation had been conducted according to the principles expressed in the Declaration of Helsinki. All participants signed an informed consent form. The methods used in this study did not intimidate participants, and recruiters were instructed to ask about any discomfort with the protocol or with Facebook data extraction.

2.2. Recruitment

We recruited patients with BD I and II, diagnosed according to Diagnostic and Statistical Manual of Mental Disorders, 5th edition (DSM-V) criteria, among subjects attending the outpatient clinic for Bipolar Disorders at Hospital de Clínicas de Porto Alegre, Universidade Federal do Rio Grande do Sul, in Porto Alegre, Brazil (PROTAHBI). The participants were interviewed by a psychiatrist (using SCID), who checked if patients were not in an acute mood episode when consenting to participate in the study, according to DSM-V criteria.

Eligible participants were patients between 18 and 65 years of age who had a Facebook account with at least one year of use, which could not have been shared by other people, and a computer or a smartphone with internet access. Exclusion criteria were the presence of neurological disease, current substance abuse criteria

or any physical condition that could restrict the patient's ability to use a computer or to provide informed consent.

2.3. Social demographic and clinical assessment

A psychologist, psychiatrist or trained personnel applied a standard protocol examining sociodemographic variables (age, years of education, sex, marital status, and occupation). Participants were also required to attend a psychiatric evaluation that included diagnostic assessment (Structured Clinical Interview for DSM-V, SCID), symptom rating using the Hamilton Rating Scale for Depression (HAM-D) (Hamilton, 1960) and Young-Mania-Rating Scale (YMRS) scales. We used NIMH Life Chart Manual for Recurrent Affective Illness - Clinician Retrospective Chart (Leverich G & Post R, 2002) to chart the progress of BD over the past year in order to correlate this data with Facebook usage. Moreover, the Functional Assessment Staging Tool (FAST) was used to check patients functionality.

In addition to cross-sectional data and retrospective 1-year Facebook data extraction, we initiated the collection of prospective 1-year follow-up data (every six months, with 24 months of observation in total). On a prospective follow-up visit participants were invited to give permission for new Facebook data extraction, as well as to complete NIMH, YMRS, HAM-D, FAST, sociodemographic protocol again.

2.4. Facebook Activity Log download

Participants logged into their Facebook accounts for anonymized data download. While viewing the Facebook Activity Log page, patients were asked to disable chat features and remain on the side of the researcher throughout extraction. Data from the Activity Log corresponding to the previous year was saved anonymously as an HTML file with the information of the webpage. We did not keep any passwords during the extraction process.

2.5. Data extraction from activity logs

We developed a MATLAB code (available upon request) to analyze the HTML files derived from the Facebook activity log. Briefly, the program found the unique code tags that divided the activity by months and years. Then, for each month, it assessed the total number of identifier tags for the following metrics: likes; comments; shares; status updates; relationship updates; profile and cover photo updates; added photo

or video; photos tagged; mentions in comments; friends asked; friends added; posts in other peoples' timeline; posts from other people in participant's timeline; events attended; and groups joined. For content analysis, we automatically extracted texts from posts and comments and saved as separated text files, also divided by month, which were then analyzed by LIWC. The software was extended to look into the code for data only within 12 months before the activity log download.

2.6. LIWC

The data extracted from all written content extracted from HTML (posts and comments) was divided into units of words that were automatically classified by the Linguistic Inquiry and Word Count (LIWC) software (Pennebaker et al., 2007) to obtain frequency of categories. The content of the posts was used to calculate the number of times that certain groups of words appeared and the relationships between different words through an automated text analysis. LIWC includes 64 categories measuring emotional, cognitive, and structural components contained in text. We used the Brazilian Portuguese version of the 2001 LIWC dictionary (Balage Filho et al., 2013). As our idea was to characterize and differentiate patients with depression, mania, and euthymia, our primary interest lay in the semantic categories related to affective processes, namely: (a) positive emotion, (b) negative emotion, (c) anxiety, (d) anger and (e) sadness. Other categories, however, were also analyzed in an exploratory way.

2.7. Statistical Analysis

We performed statistical analyses in R (<https://www.Rproject.org/>). We used mood data from NIMH Life Chart and Facebook usage and semantic data from 31 patients, utilizing each patient-month as an observational unit. In total, we gathered 387 patient-months (N=387), with each of them corresponding to a mood state, as well as multiple usage and semantic variables. At the mood, we entered the main one of the month (e.g., euthymia, depression or mania). For analyses, mania had to be excluded of the sample, once patients' months with mania were not enough when compared to the greater number of euthymic' one (final number of months: mania 43; depression 94 and euthymia 216). We also had to exclude nine months with depressive data and 25 with euthymic, because we could not run an analysis with missing information.

2.8. Z-score

We transformed semantic variables, age and years of education of subjects during depressive periods to Z-score based on the mean and standard deviation of the same individuals during euthymic periods according to the NIMH Life Chart. We truncated extreme values of z-scores (<-4.0 or >4.0) to $z = -4.0$ or $z = 4.0$.

2.9. Support Vector Machine

We selected eight predictors to train the algorithm: age, years of education, sex, positive emotion (posemo), negative emotion (negemo), anxiety (anx), anger and sadness (sad). We used the radial basis function kernel in the Support Vector Machine algorithm with 10-fold cross-validation to conduct internal validation. We performed Synthetic Minority Over-Sampling Technique (SMOTE) to solve the class imbalance problem. The validity of the algorithm in classifying individuals with depressive mood and without depressive mood was evaluated using sensitivity, specificity, positive and negative predictive value and balanced accuracy. We computed and reported the Receiver Operating Characteristic (ROC) curve and Area Under Curve (AUC). Statistical significance was defined at $p < 0.05$.

3. Results

A total of 194 patients from bipolar disorder outpatient clinic were approached. Of these, 86 were not eligible for the study (66 did not use Facebook at all, 16 were 70 years or older; 4 were diagnosed with schizoaffective disorder), 3 fulfilled exclusion criteria (were diagnosed with comorbid intellectual disability); 48 refused to participate, and 24 we could not reach due to wrong or outdated contact data.

A final total of 33 patients were included and longitudinal Facebook data extracted. Of these, two could not be included due to technical problems with the Facebook data extraction. A final sample of 31 patients was evaluated. This group showed a mean of 12.44 months of follow-up (4 less than 12 months, 23 completed 12 months and four patients with 19-24 months of follow-up). The patients who showed less than 12 months of data extraction was due to random technical problems with the HTML data extraction. Those with more extended periods of observation were invited to reevaluate after 12 months of baseline interview, but

there was difficult to get them to come back to the hospital so that at the time of analysis only four patients have reached this point. Patients were 41.84 ± 11.01 years old, were mostly female (23), had on average 11.39 ± 3.92 years of education, and most of them (18) were married. Most patients were euthymic at the moment of the interview (YMRS = 3.84 and HAM-D = 8.71), and their functionality as measured by FAST was 30.23 ± 15.62 . Their illness had been diagnosed for an average of 20.6 ± 13 years, and they had an average of 13.8 ± 10 lifetime mood episodes.

Table 1. Demographic and clinical characteristics.

Category	Subcategory	Subcategory	Patients (n=31)
Demographic	Age		41.84 (11.01)
	Sex	Female	23
	Years of education		11.39 (3.92)
	Marital Status	Married	18
Clinical			
	YMRS		3.84 (4.06)
	HAM-D		8.71 (6.23)
	FAST (30)		30.23 (15.62)
	Duration of illness		20.64 (12.996)
	Total episodes (29)		13.76 (9.94)
	Hospitalizations		3.22 (3.48)
	Suicide attempts		1.71 (1.81)
	Diagnosis	BDI	22
		BDII	6
	Episode onset (28)	Mania	10
		Hypomania	5
		Depression	15
Facebook extraction	Total		31
	12 months		23
	Less than a year		4
	More than a year		4

YMRS = Young Mania Rating Scale; HAM-D = Hamilton Depression Rating Scale; FAST = Functional Assessment Screening Tool;

The support vector machine algorithm with radial basis function achieved a balanced accuracy of 83% and high sensitivity (87.5%) and specificity (78.6%), classifying subjects correctly with depressive mood (negative predictive value = 73.3%) and euthymic subjects (positive predictive value = 90.3%) according to the multivariate model. The area under of ROC curve was 86.7% (Fig. 1).

The model without the variables age, years of education and sex reached a balanced accuracy of 54.4%, a high sensitivity (37.5%) and specificity (71.4%), classifying subjects correctly with depressive mood (negative predictive value = 33%) and euthymic subjects (positive predictive value = 75%) according to the multivariate model. The area under of ROC curve was 53.5% (Fig. 3).

The most important predictors in distinguishing euthymic individuals from individuals with depressive mood according to SVM were words with the meaning of anxiety (56.1), age (47.6), anger (39.5) , years of education (25.5), sad (23.3), negative emotion (23.0), positive emotion (17.4), and sex (6.0). Please see Figure 2.




Figure 1 - ROC curves of Support Vector Machine (SVM) with radial basis function kernel for classifying subjects with depressive mood and euthymic subjects according to words with the meaning of affective processes published on Facebook.




Figure 2 - The semantic signature of patients with mood depressive and euthymic patients according to words used on Facebook.




Figure 3 - ROC curves of Support Vector Machine (SVM) with radial basis function kernel for classifying subjects with depressive mood and euthymic subjects according to words with the meaning of affective processes published on Facebook (without variables of sex, age and years of education).

4. Discussion

This is the first study to evaluate detection of bipolar depressive episodes using longitudinal direct data extraction from Facebook, with patient private data permission. Previous studies have examined mostly unipolar depressive episodes (14) and analyzed open online content (15) or have examined other social media (3). As expected for complex phenomena, we found that depressive episodes in bipolar disorder are difficult to predict using a model based on social media information. However, the linguistic analysis using LIWC associated with age and education variables included in a machine learning approach predicted depressive episodes better than chance, with an accuracy of AUC 86.7%. When the model included only the affective words protocol of LIWC, the prediction became weak, with an accuracy of AUC 53.5%. Based on this, we suggest that linguistic analysis of Facebook content may be worth to be included in future predictive models of depression, but may be associated with other variables to increase the accuracy of the model. This is in line with previous studies, and it is a reasonable result given the complexity of the clinical feature we are trying to predict. While semantic evaluation was associated with depressive episodes, the inclusion of Facebook usage metrics did not add much accuracy to the model. These results may be explained in part by the high variability on usage between subjects as well as a small sample size; but also by the high level of noise found in Facebook activities, reported by previous studies (Nguyen T, Armstrong W, Shrivastava A, online).

Interestingly, most of the models we explored showed greater positive predictive value for depressive episode than negative predictive value, suggesting that this strategy may be more suitable for screening purposes and promoting alert tools rather than for diagnostic or exclusion purposes, as expected.

These results should be interpreted in the light of its strengths and limitations. First, we included only patients who were not in an acute episode, but we cannot assure about the effect of subsyndromal symptoms on recall bias, even though the propose of the study was to detect acute mood episodes. Second, despite the advantage of direct data extraction from Facebook, we collected the data backward

(from the last year) and correlated with NIMH life chart retrospective. Despite the use of a well-validated instrument to collect retrospective data, we cannot exclude that memory bias may have influenced the results. Third, the follow-up of these patients was variable, and we used the month as a unit for analysis, to allow the use of machine learning approach in a small sample regarding the number of patients but greater concerning observations units. This approach may have contributed to a better understanding of complex data, but we used the month as an observational unit instead of each subject, which may directly impact the interpretation of the model. Notwithstanding these limitations, the current study serves as a proof-of-concept and raises essential aspects in the detection of depressive episodes based on social media data. Based on the results, it became clear that demographic variables were an important part of the model, once there was a significant difference of accuracy between the model with these variables and that without (only with LIWC). Nevertheless, a subgroup of affective processes – anxiety – was an important variable of the model that achieved AUC 86.7%. Finally, we are aware that multiple analysis were examined in the database and should be considered exploratory, given the small sample size for such number of variables in a model; however, we decided to report them as a secondary analysis. These suggest that metrics on Facebook did not add accuracy to prediction model, and corroborate previous studies suggesting there may be much noise in this variables. On the other hand, one could argue that there were not enough observations to train the model, therefore, compromising the accuracy. The model would probably benefit from a more substantial number of observations from different subjects in future studies.

Acknowledgments

This work was supported by Fundo de Incentivo a Pesquisa e Eventos – Hospital de Clínicas de Porto Alegre and by the National Science and Technology Institute for Translational Medicine, with the financial support of Coordenação de Aperfeiçoamento de Pessoal de Nível Superior and Conselho Nacional de Desenvolvimento Científico e Tecnológico. The funders had no role in study design, data collection and analysis, decision to publish, or in manuscript preparation.

5. References:

- American Psychiatric Association. (2013). Diagnostic and statistical manual of mental disorders (5th ed.). Arlington, VA: American Psychiatric Publishing.
- Balage Filho PA, Pardo TAS, Aluísio SM (2013). An evaluation of the Brazilian Portuguese LIWC for sentiment analysis. Proceedings of the 9th Brazilian Symposium in Information and Human Language: 215-219.
- Birjali M, Beni-Hssane A, Erritali M. Machine Learning and Semantic Sentiment Analysis based Algorithms for Suicide Sentiment Prediction in Social Networks. *Procedia Computer Science* 113 (2017) 65–72.
- Birnbaum ML, Ernala SK, Rizvi AF, De Choudhury M, Kane JM. A Collaborative Approach to Identifying Social Media Markers of Schizophrenia by Employing Machine Learning and Clinical Appraisals. Eysenbach G, ed. *Journal of Medical Internet Research*. 2017;19(8):e289.
- Birnbaum ML, ErnalaSK, RizviAF, De ChoudhuryM, Kane JM. A Collaborative Approach to Identifying Social Media Markers of Schizophrenia by Employing Machine Learning and Clinical Appraisals. EysenbachG, ed. *Journal of Medical Internet Research*. 2017;19(8):e289.
- Bopp JM, Miklowitz DJ, Goodwin GM, Stevens W, Rendell JM, Geddes JR. The longitudinal course of bipolar disorder as revealed through weekly text-messaging: a feasibility study. *Bipolar disorders*. 2010;12(3):327-334.
- Braithwaite SR, Giraud-Carrier C, West J, Barnes MD, Hanson CL. Validating Machine Learning Algorithms for Twitter Data Against Established Measures of Suicidality. BamidisP, ed. *JMIR Mental Health*. 2016;3(2):e21.
- Cardoso T, Bauer IE, Meyer TD, Kapczinski F, Soares JC. Neuroprogression and Cognitive Functioning in Bipolar Disorder: A Systematic Review. *Curr Psychiatry Rep* (2015) 17: 75.
- Choudhury MD, Gamon M, Counts S, and Horvitz E. Predicting depression via social media. In *Proceedings of the International Conference on Weblogs and Social Media*, pages 128–137, 2013.
- Dean BB, Gerner D, Gerner RH (2004) A systematic review evaluating health-related quality of life, work impairment, and healthcare costs and utilization in bipolar disorder. *Curr Med Res Opin* 20:139–154
- Facebook Newsroom Brazil, accessed Apr-20-2018 <https://br.newsroom.fb.com/company-info/>
- Facebook Newsroom World, accessed Apr-20-2018 <https://newsroom.fb.com/company-info/>
- Guntuku SC, Yaden DB, Kern ML, Ungar LH and Eichstaedt JC. Detecting depression and mental illness on social media: an integrative review. *Current Opinion in Behavioral Sciences* 2017, 18:43–49.
- Insel TR. Digital Phenotyping Technology for a New Science of Behavior. *JAMA*. 2017;318(13):1215–1216.
- Jain SH, Powers BW, Hawkins JB, Brownstein JS. The digital phenotype. *Nat Biotechnol*. 2015 May;33(5):462-3.
- Karasouli E, Adams A. Assessing the evidence for e-resources for mental health self-management: a systematic literature review. *JMIR Ment Health*. 2014;1:e3.
- Kauer-Sant'Anna M, Bond DJ, Lam RW, Yatham LN (2009) Functional outcomes in first-episode patients with bipolar disorder: a prospective study from the Systematic Treatment Optimization Program for Early Mania project. *Compr Psychiatry* 50(1): 1–8.
- Kessler RC, Chiu WT, Demler O, Merikangas KR, Walters EE. Prevalence, severity, and comorbidity of 12-month DSM-IV disorders in the National Comorbidity Survey Replication. *Arch Gen Psychiatry*. 2005 Jun;62(6):617-27.

Leverich G & Post R, 2002 - NIMH Life Chart Manual for Recurrent Affective Illness - Clinician Retrospective Chart (NIMH - LCM CRC)

Martini T, Czepielewski LS, Fijtman A, Sodré L, Wollenhaupt-Aguiar B, Pereira CS, Vianna-Sulzbach M, Goi PD, Rosa AR, Kapczinski F, Kunz M, Kauer-Sant'Anna M. (2013) Bipolar Disorder Affects Behavior and Social Skills on the Internet. *PLoS ONE* 8(11): e79673.

Martini TC, Czepielewski L, Prates-Baldez D, Gliddon E, Kielling C, Berk L, Berk M, Kauer-Sant'Anna, M. Mental health information online: what we have learned from social media metrics in BuzzFeed's Mental Health Week. *Trends in Psychiatry and Psychotherapy*. 2018. Accepted for publication.

Max Hamilton. 1960. A rating scale for depression. *Journal of neurology, neurosurgery, and psychiatry* 23(1):56.

National Institute of Mental Health. (2018). Bipolar Disorder. Retrieved from <https://www.nimh.nih.gov/health/topics/bipolar-disorder/index.shtml>

Nguyen T, Armstrong W, Shrivastava A. Using Deep Linguistic features to predict Depression. Online. Available at http://legacydirs.umiacs.umd.edu/~daithang/final_report_773.pdf

Nguyen T, O'dea B, Larsen M, Phung D, Venkatesh S, and Christensen H. 2017. Using linguistic and topic analysis to classify sub-groups of online depression communities. *Multimedia Tools Appl.* 76, 8 (April 2017), 10653-10676.

Nguyen T, Phung D, Dao B, VenkateshS and BerkM, "Affective and Content Analysis of Online Depression Communities," in *IEEE Transactions on Affective Computing*, vol. 5, no. 3, pp. 217-226, July-Sept. 1 2014.

Park G, Schwartz HA, Eichstaedt JC, et al. (2014). Automatic personality assessment through social media language. *J Pers Soc Psychol.* Epub ahead of print.

Pennebaker JW, Boot RE and Francis ME, (2007). "Linguistic inquiry and word count: LIWC2007 - Operator's manual." Austin, TX: LIWC.net

R Core Team (2013). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.

Rosa AR, Sánchez-Moreno J, Martínez-Aran A, Salamero M, Torrent C, et al. (2007) Validity and reliability of the Functioning Assessment Short Test (FAST) in bipolar disorder. *Clin Pract Epidemiol Ment Health* 3: 5.

Schwartz HA, Eichstaedt JC, Kern ML, et al. (2012). Personality, gender, and age in the language of social media: the open vocabular approach. *PLoS ONE* 8(9): e73791.

Settanni M, Marengo D. Sharing feelings online: studying emotional well-being via automated text analysis of Facebook posts. *Frontiers in Psychology*. 2015;6:1045.

Shen G, Jia J, Nie L, Feng F, Zhang C, Hu T, Chua TS and Zhu W. 2017. Depression Detection via Harvesting Social Media: A Multimodal Dictionary Learning Solution. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence (IJCAI-17)*.

Young RC, Biggs JT, Ziegler VE, Meyer DA (1978) A rating scale for mania: reliability, validity and sensitivity. *The British Journal of Psychiatry* 133: 429–435.

Young SD. Behavioral insights on big data: using social media for predicting biomedical outcomes. *Trends Microbiol.* 2014. Nov; 22(11): 601-602.

Zubieta JK, Huguelet P, O'Neil RL, Giordani BJ (2001) Cognitive function in euthymic bipolar I disorder. *Psychiatry Res* 102: : 9 –20.

7. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Este trabalho buscou avaliar o potencial das mídias sociais como preditoras da depressão no transtorno bipolar e como promotoras de saúde mental na internet. Em resumo, este estudo verificou que os pacientes com TB de fato estão conectados nas mídias sociais, buscam por informações de saúde mental e postam dados importantes em suas mídias. Neste processo, eles revelam uma infinidade de dados que podem ser utilizados como uma janela para compreender processos complexos, como alterações de humor no transtorno bipolar. Tanto a intensidade do uso das mídias sociais quanto o conteúdo produzido pelos pacientes podem ter correlação com alterações do humor, oferecendo a possibilidade de detecção precoce e acompanhamento dessas alterações. O termo fenótipo digital surgiu para descrever esta abordagem de medição do comportamento.

O objetivo principal do primeiro artigo desta tese foi delineado para analisar as interações da Semana de Saúde Mental do BuzzFeed (BFMHW) em seu próprio site e em plataformas de mídia social relacionadas (Facebook, Twitter e YouTube) usando métricas de entrega de informações em tópicos de saúde mental. De forma específica, buscou-se identificar estratégias de marketing de redes sociais utilizadas para promover a saúde mental e reduzir o estigma em intervenções *on-line*, através da BFMHW e mídias acima citadas. A hipótese confirmada para este artigo é a descrição e identificação de estratégias de marketing utilizadas pelo BuzzFeed para a propagação de conteúdo, o que trouxe uma ampla gama de tópicos, úteis para a produção de novos conteúdos de promoção de saúde mental nas mídias.

De forma geral, a análise sugere que quanto maior o número de plataformas de mídias sociais alcançadas por um post, maiores as taxas de visualização. Ainda, a análise revelou dados importantes sobre a promoção da saúde mental *on-line*. O estudo de caso da iniciativa SSM do BuzzFeed sugere que a informação pode ser mais eficaz para alcançar o público se entregue em formato de vídeo, se compartilhada em mais de uma mídia, se incluir experiência pessoal, algum humor no conteúdo e informações mais detalhadas sobre tipos e formato de tratamento.

Recursos audiovisuais são muito utilizados pelos geradores de conteúdo hoje em dia e, particularmente no YouTube, o formato de vídeo tem audiências cada vez maiores. O Facebook apesar de ser uma plataforma de rede social importante e

muito frequentada, não ultrapassa o YouTube em visualizações e envolvimento, até mesmo porque gera suas próprias métricas de consumo. Nos resultados do artigo 1, no entanto, viu-se que vídeos compartilhados também no Facebook foram visualizados com mais frequência em um total do que aqueles distribuídos apenas pelo YouTube.

Os resultados também mostraram que o envolvimento do público está associado ao número de mídias em que o conteúdo é publicado, e não ao tempo disponível on-line. Os sites de mídias sociais de notícias, como o BuzzFeed, tem utilizado o compartilhamento em diferentes redes sociais, o que resulta em mais envolvimento do público. Estas estratégias requerem o conhecimento da plataforma a ser utilizada e links a serem compartilhados. Muitas iniciativas em saúde mental fracassam na tentativa de utilizar a popularidade das mídias sociais, uma vez que não utilizam o conteúdo no formato correto, nem promovem o compartilhamento devido dos dados postados.

Com base no tópico sobre o papel das mídias sociais para a promoção de saúde mental, salienta-se a importância da atenção que conteúdos relacionados ao risco de suicídio ganharam nos últimos tempos. No artigo 1 foi encontrado um grande interesse do público no assunto, o que leva a concluir que é possível que esteja sendo produzido menos para o que demanda a população num geral. Entre outros assuntos com maior destaque nos achados deste artigo foram a depressão e o tratamento, este último levando-se em conta a importância de uma abordagem mais informal, que possa informar e divertir o internauta ao mesmo tempo.

No total, foram 44 vídeos e posts analisados, onde foi realizada observação através de métricas de redes sociais *on-line*. O conteúdo ainda foi avaliado quanto ao formato e conteúdo, embora esta análise tenha sido conduzida de forma exploratória em formato categórico com dados descritivos. Em futuros trabalhos, salienta-se a importância do desenvolvimento de estudos com o enfoque relacionado ao conteúdo destes sites. A tecnologia e o acesso à informação são uma realidade atual para um número crescente de pessoas, expandir a literatura pode ser um importante fator para envolver as pessoas em futuras intervenções na internet.

O segundo artigo, intitulado "*Digital phenotype of bipolar depression: a machine-learning approach based on Facebook data*" possuía como objetivo averiguar se o uso da mídia social escolhida, o Facebook (FB), poderia prever a depressão no transtorno bipolar, através da coleta de dados dos pacientes com TB.

Nesta análise foram utilizados dados extraídos do FB, que foram observados quanto a estrutura e conteúdo semântico das postagens através do dicionário LIWC e quanto ao resultado do estado de humor indicado pela NIMH Life Chart em entrevista clínica presencial, ambos coletados retrospectivamente um ano. Como objetivo específico do segundo artigo, foi proposto averiguar baseados nas métricas de extração de uso do FB, se o volume de atividades poderia prever o estado de humor dos pacientes com TB, indicados pela NIMH Life Chart, ambos dados coletado retrospectivamente um ano.

Ambas as hipóteses afirmavam que alguns elementos tanto da estrutura e conteúdo das postagens quanto do volume de atividade no FB poderiam prever a depressão no transtorno bipolar. As hipóteses foram confirmadas parcialmente, uma vez que os resultados devem ser interpretados com algumas limitações. A análise mostrou que o grupo de palavras de afetividade possui um valor preditivo importante para a depressão bipolar quando associado a algumas variáveis conhecidas na literatura pela característica clássica preditiva, tais como idade, sexo e anos de estudo (AUC 86.7%). Uma vez retiradas estas variáveis, o valor preditivo perde a força (AUC 53.5%).

Estas limitações mostram que o LIWC, instrumento consolidado na literatura, é um recurso importante para direcionar tendências preditivas para depressão bipolar através do uso da internet. No entanto, entre os fatores que possivelmente contribuíram para este resultado, é o uso de escalas aplicadas por profissionais. As escalas que permitem auto-avaliação possuem a vantagem de utilizar um tamanho amostral maior, mas podem ter uma relação enviesada de observação. Poucos estudos utilizaram escalas clínicas para as análises com LIWC, o que nos leva a considerar a hipótese de que este método de análise de conteúdo semântico pode não ser o melhor indicador para prever a depressão bipolar através do conteúdo de mídias sociais. Mais estudos devem ser realizados para que se possa ter uma noção mais clara da relação das métricas extraídas de mídias sociais com o transtorno bipolar.

Das principais características deste trabalho, a personalização na coleta de dados, tanto clínicos quanto no FB, que foi feita com cada participante, pode ter diferenciado os resultados. Diversos estudos analisaram dados e perfis públicos espalhados em diversas mídias (i.e., Twitter, Live Journal, Facebook). Neste trabalho a equipe treinada para este fim, sem tomar conhecimento da senha, pedia para o

paciente logar em seu perfil do FB, com eles presentes. Eles colocavam a senha no computador, e ficavam ao lado do monitor para observação, durante o período de extração dos dados. Neste trabalho foi utilizado o HTML do registro de atividades do Facebook até 1 ano retrospectivo. Entre as dificuldades durante este carregamento de dados, muitas vezes, ocorriam erros na página e/ ou, a coleta se estendia devido a quantidade de uso acentuada de alguns pacientes.

De fato, as dificuldades metodológicas devem ser levadas em consideração na interpretação dos resultados. Houve dificuldade de recrutamento de pacientes que tivessem a disponibilidade de tempo e interesse em autorizar a inserção de sua senha do Facebook no computador do grupo de pesquisa. De forma especulativa, é possível que uma combinação de dificuldade e custo de acesso ao hospital terciário, de características mais paranóides ou de baixo funcionamento possam ter influenciado. Desta forma, o período de coleta se estendeu por quase dois anos, incluindo período de estágio doutoral na Austrália.

O estudo ainda envolveu a participação de uma equipe de colaboradores da UFRJ, que desenvolveram um código MatLab para analisar os arquivos HTML derivados do log de atividades do Facebook dos pacientes. Este programa encontrava as *tags* de código exclusivas que dividiam a atividade por meses e anos. Para análise de conteúdo, a equipe ainda extraiu os textos das postagens e comentários que foram salvos como arquivos de texto separados, também divididos por mês, para daí então serem analisados pelo LIWC.

Este estudo foi desafiador em todo o seu período. Para as análises, especialmente, chegou-se a conclusão que um tamanho amostral de 31 pacientes não seria adequado para o tipo de análise com *machine learning*. A diversidade da forma de extração descrita na literatura criou a necessidade de padronizar esta metodologia. Em nossos bancos existiam muitos dados de cada paciente, com informações detalhadas mês a mês. Então, cada mês com dados completos de humor (medido através da escala NIMH Life Chart) e com a extração dos dados do registro de atividades do Facebook foram transformados em unidades para análise, atingindo um tamanho amostral superior, com 310 meses com dados completos. Após esta transformação, as variáveis brutas foram normalizadas para análise de *Support Vector Machine (SVM)*, realizado no programa R. Estamos cientes de que múltiplas análises foram examinadas no banco de dados e devem ser consideradas

exploratórias, dado o pequeno tamanho da amostra para esse número de variáveis em um modelo; no entanto, decidimos reportá-los como uma análise secundária.

As métricas de uso do Facebook ainda são pouco estudadas na literatura e merecem um destaque maior. É possível observar a utilidade para estes dados em ambos artigos. No primeiro, foi encontrada uma extensa literatura de marketing digital que trouxe interessantes *insights* para a análise do conteúdo da amostra, incluindo as métricas de engajamento. No segundo, utilizamos diferentes modelos incluindo de formas variadas estas variáveis agrupadas e reportamos o modelo que obteve o melhor desempenho.

Entre as limitações do presente trabalho estão o tamanho amostral já citado anteriormente; a ausência suficiente de pacientes com meses em mania (amostra excluída pelo número muito inferior dos meses dos grupos de depressão e eutímia); e ausência de controles hígidos pareados por sexo, anos de estudo e idade, para comparar a semântica e uso dos dois grupos. Com isto, seria possível estabelecer uma relação entre os pacientes e o impacto do TB nas mídias sociais, através dos dados de utilização e semântica. Estas informações podem nos trazer mais claramente dados de como paciente se comportam durante episódios ao utilizar mídias sociais.

Em suma essa tese esclarece acerca do papel das mídias sociais na avaliação diagnóstica da depressão bipolar. Mais estudos são necessários para que possamos explorar com mais precisão o fenótipo digital como tecnologia para uma nova ciência do comportamento. A tecnologia surpreende pela existência de computadores que coletam contínua e passivamente dados sobre atividade, localização e engajamento social. Estas impressões digitais individuais podem tornar-se um possível sinal de alerta precoce de doença mental grave. Estas possibilidades certamente transformariam as vidas de pessoas com estes diagnósticos, e também revolucionariam entrevistas de humor, cognição e comportamento na pesquisa e prática clínica.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- Andersson G, Bergstrom J, Hollandare F, Carlbring P, Kaldov V, Ekselius L. Internet-based self-help for depression: randomised controlled trial. *British Journal of Psychiatry*. 2005, 187, 456-461.
- Baez S, Herrera E, Villarin L, Theil D, Gonzalez-Gadea ML, et al. Contextual Social Cognition Impairments in Schizophrenia and Bipolar Disorder. *PLoS ONE*. 2013, 8(3): e57664.
- Balage Filho PA, Pardo TAS, Aluísio SM. An evaluation of the Brazilian Portuguese LIWC for sentiment analysis. *Proceedings of the 9th Brazilian Symposium in Information and Human Language: 2013*, 215-219.
- Berk L, Berk M, Dodd S, Kelly C, Cvetkovski S, Jorm FA. Evaluation of the acceptability and usefulness of an information website for caregivers of people with bipolar disorder. *BMC Medicine*. 2013, 11:162.
- Betton V, Borschmann R, Docherty M, Coleman S, Brown M, Henderson C. The role of social media in reducing stigma and discrimination. *Br J Psychiatry*. 2015; 206:443-4.
- Birjali M, Beni-Hssane A, Erritali M. Machine Learning and Semantic Sentiment Analysis based Algorithms for Suicide Sentiment Prediction in Social Networks. *Procedia Computer Science*. 2017, 113:65–72.
- Birnbaum ML, Ernala SK, Rizvi AF, De Choudhury M, Kane JM. A Collaborative Approach to Identifying Social Media Markers of Schizophrenia by Employing Machine Learning and Clinical Appraisals. Eysenbach G, ed. *Journal of Medical Internet Research*. 2017;19(8):e289.
- Braithwaite SR, Giraud-Carrier C, West J, Barnes MD, Hanson CL. Validating Machine Learning Algorithms for Twitter Data Against Established Measures of Suicidality. Bamidis P, ed. *JMIR Mental Health*. 2016; 3(2):e21.
- BuzzFeed. Mental Health Week [website]. [cited 14 June 2017]. <https://www.buzzfeed.com/mentalhealthweek>
- BuzzFeed. Mental Health Week [website]. [cited 14 June 2017]. <http://bzfd.it/2saaReg>
- Choudhury MD, Gamon M, Counts S, and Horvitz E. Predicting depression via social media. In *Proceedings of the International Conference on Weblogs and Social Media*. 2013, p. 128–137.
- Christensen H, Griffiths KM, Farrer L. Adherence in internet interventions for anxiety and depression. *J Med Internet Res*. 2009;11:e13.
- Christensen H. Social media: The new e-mental health tool. *InPsych [Internet]*. 2014 Jun [cited 2018 May 20]; 36 (3): [about 1 p.]. Available from: <https://www.psychology.org.au/inpsych/2014/june/christensen>
- Christensen H, Griffiths KM, Jorm AF. Delivering interventions for depression by using the internet: randomised controlled trial. *BMJ*. 2004, 328(7434), 265.
- Cohen S, Doyle WJ, Skoner DP, Rabin BS, Gwaltney JM Jr. Social ties and susceptibility to the common cold. *JAMA*. 1997, 277(24):1940-4.
- Cohen T, Blatter B, Patel V. Simulating expert clinical comprehension: Adapting latent semantic analysis to accurately extract clinical concepts from psychiatric narrative. *J Biomed Inform*. 2008, 41:1070-87.
- Colom F, Vieta E, Sanchez-Moreno J, Martinez-Aran A, Reinares M, Goikolea JM, et al. Stabilizing the stabilizer: group psychoeducation enhances the stability of serum lithium levels. *Bipolar Disord*. 2005;7 Suppl 5:32–6.

Colom F, Vieta E, Sánchez-Moreno J, Palomino-Otiniano R, Reinares M, Goikolea JM, Benabarre A, Martínez-Arán A. Group psychoeducation for stabilised bipolar disorders: 5-year outcome of a randomised clinical trial. *Br J Psychiatry*. 2009 Mar;194(3):260-5.

Colom F, Vieta E, Sánchez-Moreno J, Palomino-Otiniano R, Reinares M, Goikolea JM, Benabarre A, Martínez-Arán A. Group psychoeducation for stabilised bipolar disorders: 5-year outcome of a randomised clinical trial. *Br J Psychiatry*. 2009 Mar; 194(3):260-5.

Coryell W, Scheftner W, Keller M, Endicott J, Maser J, Klerman GL. The enduring psychosocial consequences of mania and depression. *Am J Psychiatry*. 1993, 150:720-727.

Cox-George C. The changing face(book) of psychiatry: can we justify “following” patients’ social media activity? *BJPsych Bull*. 2015;39:283-4.

Crutzen R, Ruiters RA, de Vries NK. Can interest and enjoyment help to increase use of Internet-delivered interventions? *Psychol Health*. 2014;29:1227-44.

Cusi AM, Nazarov A, Holshausen K, MacQueen GM, McKinnon MC. Systematic review of the neural basis of social cognition in patients with mood disorders. *J Psychiatry Neurosci*. 2012, 37(3) 154-169.

Facebook Newsroom. Dia Mundial de Prevenção ao Suicídio. Post creation November 27th, 2017, accessed May 20th 2018. Retrieved from <https://br.newsroom.fb.com/news/2017/09/dia-mundial-de-prevencao-ao-suicidio/>.

Elvevag B, Foltz PW, Rosenstein M, DeLisi LE. An automated method to analyze language use in patients with schizophrenia and their first-degree relatives. *J Neurolinguistics*. 2010, 23:270-284.

Facebook Newsroom Brazil, accessed Apr-20-2018 <https://br.newsroom.fb.com/company-info/>

Fowler JH, Christakis NA. Dynamic spread of happiness in a large social network: longitudinal analysis over 20 years in the Framingham Heart Study. *Br Med J*. 2008, 337: a2338.

Guntuku SC, Yaden DB, Kern ML, Ungar LH and Eichstaedt JC. Detecting depression and mental illness on social media: an integrative review. *Current Opinion in Behavioral Sciences*. 2017, 18:43–49.

Hatfield E, Cacioppo JT, Rapson RL. Emotional Contagion. *Current Directions in Psychological Science*. 1993, 2(3) 96-100.

Heaney C, Israel BA. Social Networks and Social Support. In: Glanz K, Rimer BK, Viswanath K. *Health Behavior and health education: theory, research and practice*. Hoboken: John Wiley & Sons. 2008, pp. 189-210.

Hidalgo-Mazzei D, Mateu A, Reinares M, Matic A, Vieta E, Colom F. Internet-based psychological interventions for bipolar disorder: Review of the present and insights into the future. *J Affect Disord*. 2015 Dec;188:1–13.

Hirschfeld RM, Vornik LA. Bipolar disorder: costs and comorbidity. *AM J Manag Care*. 2005; 11(suppl 3):85-90.

Holt-Lunstad J, Smith TB, Layton JB. Social Relationships and Mortality Risk: A Meta-analytic Review. *PLoS Medicine*. 2010, 7 (7): e1000316.

Hubspot Academy. Understanding content marketing (content marketing certification – class transcript). [cited 2017 September 13]. <https://cdn2.hubspot.net/hub/202647/file-43774095pdf/docs/scribewisewhitepaper.beginnersguide.pdf>

Insel TR. Digital Phenotyping Technology for a New Science of Behavior. *JAMA*. 2017;318(13):1215–1216.

- Jain SH, Powers BW, Hawkins JB, Brownstein JS. The digital phenotype. *Nat Biotechnol.* 2015 May;33(5):462-3.
- Karasouli E, Adams A. Assessing the evidence for e-resources for mental health self-management: a systematic literature review. *JMIR Ment Health.* 2014;1:e3.
- Kauer-Sant'anna M, Yatham LN, Tramontina J, Weyne F, Cereser KM, et al. Emotional memory in bipolar disorder. *Br J Psychiatry.* 2008, 192(6): 458–63.
- Kelly L, Jenkinson C, Ziebland S. Measuring the effects of online health information for patients: item generation for an e-health impact questionnaire. *Patient Educ Couns.* 2013;93:433-8.
- Kelly N. Measuring social media for brand awareness. HootSuite – Social Media Dashboard. 2011. [cited 2017 September 13]. Available from: http://static.hootsuite.com/White_Paper/WhitePaper_03_HS_FullFrontalROI_Brand_Awareness.pdf
- Kessler RC, Akiskal HS, Ames M, et al. Prevalence and effects of mood disorders on work performance in a nationally representative sample of US workers. *Am J Psychiatry.* 2006; 163(9):1561-1568.
- Kietzmann J, Hermkens K, McCarthy IP, Silvestre B. Social Media? Get Serious! Understanding the Functional Building Blocks of Social Media. *Business Horizons.* 2011, Vol. 54, No. 3.
- Kilbourne AM, Cornelius JR, Han X, Pincus HA, Shad M, Salloum I, et al. Burden of general medical conditions among individuals with bipolar disorder. *Bipolar Disorders.* 2004, 6(5):368-73
- Kramer ADI, Guillory JE, Hancock JT. Experimental evidence of massive-scale emotional contagion through social networks. *Proceedings of the National Academy of Sciences.* 2014, 111, 8788–8790.
- Lam-Po-Tang, J., & McKay, D. Dr Google, MD: a survey of mental health-related internet use in a private practice sample. *Australasian Psychiatry.* 2010, 18(2), 130-133.
- Lauder S, Chester A, Castle D, Dodd S, Berk L, Klein B, Austin D, Gilbert M, Chamberlain J A, Murray G, White C, Piterman L, Berk M. Development of an online intervention for bipolar disorder. www.moodswings.net.au, Psychology, health and medicine. 2013, vol. 18, no. 2, pp. 155-165, Routledge, Oxon, England.
- Lauder S, Chester A, Berk M. Net-effect? Online psychological interventions. *Acta Neuropsychiatrica.* 2007, 19, 386-388.
- Leitan ND, Michalak EE, Berk L, Berk M, Murray G. Optimizing delivery of recovery-oriented online self-management strategies for bipolar disorder: a review. *Bipolar Disord.* 2015, Mar;17(2):115–27.
- MacNeily A. Paging Dr. Google. *Canadian Urological Association Journal.* 2013, 7(3-4), 106-107.
- Mackey TK, Schoenfeld VJ. Going "social" to access experimental and potentially life-saving treatment: an assessment of the policy and online patient advocacy environment for expanded access. *BMC Med.* 2016;14:17.
- Mackinnon A, Griffiths KM, Christensen H. Comparative randomised trial of online cognitive-behavioural therapy and an information website for depression: 12-month outcomes. *Br J Psychiatry.* 2008, 192(2), 130-134.
- Martinez-Aran A, Vieta E, Colom F, Torrent C, Sanchez-Moreno J,. Cognitive impairment in euthymic bipolar patients: implications for clinical and functional outcome. *Bipolar Disord.* 2004, 6: 224 -32.
- Martini T, Czepielewski LS, Fijtman A, Sodr e L, Wollenhaupt-Aguiar B, et al. Bipolar Disorder Affects Behavior and Social Skills on the Internet. *PLoS ONE.* 2013, 8(11): e79673.

Matthews M, Murnane E, Snyder J, Guha S, Chang P, Doherty G, Gay G. The double-edged sword: A mixed methods study of the interplay between bipolar disorder and technology use. *Computers in Human Behavior*, 2017. Volume 75, Pages 288-300.

Meyer B, Berger T, Caspar F, Beevers CG, Andersson G, Weiss M. Effectiveness of a novel integrative online treatment for depression (Deprexis): randomized controlled trial. *Journal of Medical Internet Research*. 2009, 11(2), e15.

Mota N, Furtado R, Maia PP, Copelli M, Ribeiro S. Graph analysis of dream reports is especially informative about psychosis. *Sci Rep*. 2014, 4: 3691.

Mota N, Vasconcelos NA, Lemos N, et al. Speech graphs provide a quantitative measure of thought disorder in psychosis. *PLoS One*. 2012, 7(4): e34928.

Naslund JA, Aschbrenner KA, Marsch LA and Bartels SJ. The future of mental health care: peer-to-peer support and social media. *Epidemiology and Psychiatric Sciences*, 2016.

Neiger BL, Thackeray R, Van Wagenen SA, Hanson CL, West JH, Barnes MD, et al. Use of social media in health promotion: purposes, key performance indicators, and evaluation metrics. *Health Promot Pract*. 2012;13:159-64.

Nguyen T, Armstrong W, Shrivastava A. Using Deep Linguistic features to predict Depression. UMIACS. Retrieved from: http://legacydirs.umiacs.umd.edu/~daithang/final_report_773.pdf

Nguyen T, O'dea B, Larsen M, Phung D, Venkatesh S, Christensen H. Using linguistic and topic analysis to classify sub-groups of online depression communities. *Multimedia Tools Appl*. 2017, 76, 8, 10653-10676.

Nguyen T, Phung D, Dao B, Venkatesh S and Berk M, "Affective and Content Analysis of Online Depression Communities," in *IEEE Transactions on Affective Computing*. 2014, vol. 5, no. 3, pp. 217-226.

Park G, Schwartz HA, Eichstaedt JC, et al.. Automatic personality assessment through social media language. *J Pers Soc Psychol*. 2014, Epub ahead of print.

Pennebaker JW, Boot RE and Francis ME. "Linguistic inquiry and word count: LIWC2007 - Operator's manual." Austin, TX: LIWC.net. 2007.

Peretti J. A Cross-Platform, Global Network. Post creation October 23rd, 2015, accessed June 14th, 2017. Retrieved from <http://bzfd.it/2sAccOf>.

Pew Research Center. "Internet Seen as Positive Influence on Education but Negative Influence on Morality in Emerging and Developing Nations". Washington: Pew Research Center; 2015. [cited 2017 September 13] Accessed em: <http://www.pewglobal.org/files/2015/03/Pew-Research-Center-Technology-Report-FINAL-March-19-20151.pdf>

Reece AG, Danforth CM. Instagram photos reveal predictive markers of depression. *EPJ Data Science*. 2017, 6:15.

Reinares M, Colom F, Rosa AR, Bonnín CM, Franco C, Solé B, Kapczinski F, Vieta E. The impact of staging bipolar disorder on treatment outcome of family psychoeducation. *J Affect Disord*. 2010 Jun;123(1-3):81-6.

Reinares M, Colom F, Sanchez-Moreno J, Torrent C, Martinez-Aran A, Comes M, et al. Impact of caregiver group psychoeducation on the course and outcome of bipolar patients in remission: a randomized controlled trial. *Bipolar Disord*. 2008 Jun;10(4):511-9.

Renner T, Morrissey J, Mae L, Feldman RS, Majors M. *Psico – Série A*. New York: McGraw-Hill. 2012, P.456

Rosa AR, Marco M, Fachel JMG, Kapczinski F, Stein AT, Barros HMT. Correlation between drug treatment adherence and lithium treatment attitudes and knowledge by bipolar patients. *Prog Neuropsychopharmacol Biol Psychiatry*. 2007 Jan;31(1):217–24.

Rosen G. Ajudando nossa comunidade em tempo real. Post creation November 27th, 2017, accessed May 20th 2018. Retrieved from <https://br.newsroom.fb.com/news/2017/11/ajudando-nossa-comunidade-em-tempo-real/>

Rosenquist JN, Fowler JH, Christakis NA. Social network determinants of depression. *Molecular Psychiatry*. 2011, 16: 273-281.

Sajatovic M. Bipolar disorder: disease burden. *AM J Manag Care*. 2005; 11(suppl 3): 85-90.

Schwartz HA, Eichstaedt JC, Kern ML, et al. Personality, gender, and age in the language of social media: the open vocabulary approach. *PLoS ONE*. 2012, 8(9): e73791.

Scott J, Pope M. Nonadherence with mood stabilizers: prevalence and predictors. *J Clin Psychiatry*. 2002, May;63(5):384–90.

Settanni M, Marengo D. Sharing feelings online: studying emotional well-being via automated text analysis of Facebook posts. *Frontiers in Psychology*. 2015;6:1045.

Shen G, Jia J, Nie L, Feng F, Zhang C, Hu T, Chua TS, Zhu W. Depression Detection via Harvesting Social Media: A Multimodal Dictionary Learning Solution. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence (IJCAI-17)*. 2017.

Smith B, Franl Z. Por que estamos promovendo uma Semana de Saúde Mental. Post creation December 15th, 2015, accessed May 20th 2018. Retrieved from https://www.buzzfeed.com/bensmith/why-were-doing-mental-health-week-ptg?utm_term=.objaxgOdg#.cqRLmGzeG

Tandoc Jr EC, Jenkins J. The Buzzfeedification of journalism? How traditional news organizations are talking about a new entrant to the journalistic field will surprise you! *Journalism*. 2015;18:482-500.

Torres IJ, Boudreau VG, Yatham LN. Neuropsychological functioning in euthymic bipolar disorder: a meta-analysis. *Acta Psychiatr Scand Suppl*. 2007, (434):17–26.

Yamaguchi S, Mino Y, Uddin S. Strategies and future attempts to reduce stigmatization and increase awareness of mental health problems among young people: a narrative review of educational interventions. *Psychiatry Clin Neurosci*. 2011;65:405-15.

Young SD. Behavioral insights on big data: using social media for predicting biomedical outcomes. *Trends Microbiol*. 2014 Nov; 22(11): 601-602.

YouTube. The Try Guys try therapy [Internet]. The Try Guys S05 E03. BuzzFeed Video. [cited 2015 Dec 13]. <https://www.youtube.com/watch?v=yStGdduzG64&list=PL5vtqDuUM1DItRct7SkzxdQa2ZQC0EEFh&index=1>

Ziebland S, Wyke S. Health and illness in a connected world: how might sharing experiences on the Internet affect people's health? *Milbank Q*. 2012;90:219-49.

Zubieta JK, Huguelet P, O'Neil RL, Giordani BJ. Cognitive function in euthymic bipolar I disorder. *Psychiatry Res*. 2001, 102: 9 –20.

9. ANEXOS

- a. Listagem de variáveis LIWC
- b. Flyer para recrutamento de pacientes com transtorno bipolar
- c. NIMH Life Chart adaptada para este estudo

a. Listagem de variáveis LIWC (retirado de Pennebaker et al., 2007)

5

Table 1. LIWC2007 Output Variable Information

Category	Abbrev	Examples	Words in category	Validity (judges)	Alpha: Binary/raw
Linguistic Processes					
Word count	wc				
words/sentence	wps				
Dictionary words	dic				
Words>6 letters	sixltr				
Total function words	funct		464		.97/.40
Total pronouns	pronoun	I, them, itself	116		.91/.38
Personal pronouns	ppron	I, them, her	70		.88/.20
1st pers singular	i	I, me, mine	12	.52	.62/.44
1st pers plural	we	We, us, our	12		.66/.47
2nd person	you	You, your, thou	20		.73/.34
3rd pers singular	shehe	She, her, him	17		.75/.52
3rd pers plural	they	They, their, they'd	10		.50/.36
Impersonal pronouns	ipron	It, it's, those	46		.78/.46
Articles	article	A, an, the	3		.14/.14
[Common verbs] ^a	verb	Walk, went, see	383		.97/.42
Auxiliary verbs	auxverb	Am, will, have	144		.91/.23
Past tense ^a	past	Went, ran, had	145	.79	.94/.75
Present tense ^a	present	Is, does, hear	169		.91/.74
Future tense ^a	future	Will, gonna	48		.75/.02
Adverbs	adverb	Very, really, quickly	69		.84/.48
Prepositions	prep	To, with, above	60		.88/.35
Conjunctions	conj	And, but, whereas	28		.70/.21
Negations	negate	No, not, never	57		.80/.28
Quantifiers	quant	Few, many, much	89		.88/.12
Numbers	number	Second, thousand	34		.87/.61
Swear words	swear	Damn, piss, fuck	53		.65/.48
Psychological Processes					
Social processes ^b	social	Mate, talk, they, child	455		.97/.59
Family	family	Daughter, husband, aunt	64	.87	.81/.65
Friends	friend	Buddy, friend, neighbor	37	.70	.53/.12
Humans	human	Adult, baby, boy	61		.86/.26
Affective processes	affect	Happy, cried, abandon	915		.97/.36
Positive emotion	posemo	Love, nice, sweet	406	.41	.97/.40
Negative emotion	negemo	Hurt, ugly, nasty	499	.31	.97/.61
Anxiety	anx	Worried, fearful, nervous	91	.38	.89/.33
Anger	anger	Hate, kill, annoyed	184	.22	.92/.55
Sadness	sad	Crying, grief, sad	101	.07	.91/.45
Cognitive processes	cogmech	cause, know, ought	730		.97/.37
Insight	insight	think, know, consider	195		.94/.51
Causation	cause	because, effect, hence	108	.44	.88/.26
Discrepancy	discrep	should, would, could	76	.21	.80/.28
Tentative	tentat	maybe, perhaps, guess	155		.87/.13
Certainty	certain	always, never	83		.85/.29
Inhibition	inhib	block, constrain, stop	111		.91/.20
Inclusive	incl	And, with, include	18		.66/.32

Category	Abbrev	Examples	Words in category	Validity (judges)	Alpha: Binary/raw
Exclusive	excl	But, without, exclude	17		.67/.47
Perceptual processes ^c	percept	Observing, heard, feeling	273		.96/.43
See	see	View, saw, seen	72		.90/.43
Hear	hear	Listen, hearing	51		.89/.37
Feel	feel	Feels, touch	75		.88/.26
Biological processes	bio	Eat, blood, pain	567	.53	.95/.53
Body	body	Cheek, hands, spit	180		.93/.45
Health	health	Clinic, flu, pill	236		.85/.38
Sexual	sexual	Horny, love, incest	96		.69/.34
Ingestion	ingest	Dish, eat, pizza	111		.86/.68
Relativity	relativ	Area, bend, exit, stop	638		.98/.51
Motion	motion	Arrive, car, go	168		.96/.41
Space	space	Down, in, thin	220		.96/.44
Time	time	End, until, season	239		.94/.58
Personal Concerns					
Work	work	Job, majors, xerox	327		.91/.69
Achievement	achieve	Earn, hero, win	186		.93/.37
Leisure	leisure	Cook, chat, movie	229		.88/.50
Home	home	Apartment, kitchen, family	93		.81/.57
Money	money	Audit, cash, owe	173		.90/.53
Religion	relig	Altar, church, mosque	159		.91/.53
Death	death	Bury, coffin, kill	62		.86/.40
Spoken categories					
Assent	assent	Agree, OK, yes	30		.59/.41
Nonfluencies	nonflu	Er, hm, umm	8		.28/.23
Fillers	filler	Blah, I mean, you know	9		.63/.18

“Words in category” refers to the number of different dictionary words that make up the variable category; “Validity judges” reflect the simple correlations between judges’ ratings of the category with the LIWC variable (from Pennebaker & Francis, 1996). “Alphas” refer to the Cronbach alphas for the internal reliability of the specific words within each category. The binary alphas are computed on the occurrence/non-occurrence of each dictionary word whereas the raw or uncorrected alphas are based on the percentage of use of each of the category words within the texts. All alphas were computed on a sample of 2800 randomly selected text files from our language corpus.

The LIWC dictionary generally arranges categories hierarchically. For example, all pronouns are included in the overarching category of function words. The category of pronouns is the sum of personal and impersonal pronouns. There are some exceptions to the hierarchy rules:

^a Common verbs are not included in the function word category. Similarly, common verbs (as opposed to auxiliary verbs) that are tagged by verb tense are included in the past, present, and future tense categories but not in the overall function word categories.

^b Social processes include a large group of words (originally used in LIWC2001) that denote social processes, including all non-first-person-singular personal pronouns as well as verbs that suggest human interaction (talking, sharing).

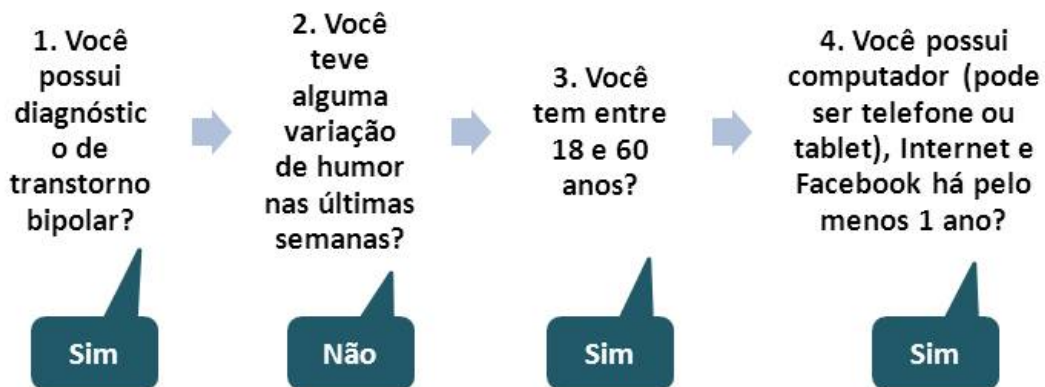
^c Perceptual processes include the entire dictionary of the Qualia category (which is a separate dictionary), which includes multiple sensory and perceptual dimensions associated with the five senses.

b. Flyer para recrutamento de pacientes com transtorno bipolar

Transtorno Bipolar, Internet e redes sociais

Olá! Você está sendo convidado para participar de um projeto de pesquisa sobre **Transtorno Bipolar e Internet**, realizado no Hospital de Clínicas de Porto Alegre.

Como participar?



Se as suas respostas forem as mesmas que as indicadas acima, você é um participante em potencial para nossa pesquisa!




Agende-se:

Use o espaço abaixo para marcar a sua participação na Fase 1 (3 entrevistas, veja ao lado)

Entrevista A	Entrevista B	Entrevista C
Dia: _____	Dia: _____	Dia: _____
Hora: _____	Hora: _____	Hora: _____
Local: _____ _____	Local: _____ _____	Local: telefone

O que é transtorno bipolar (TB) e qual é a relação com Internet e redes sociais?

O **transtorno bipolar** é um transtorno psiquiátrico que se caracteriza por grandes oscilações do humor. As variações costumam ocorrer entre dois polos: a **mania** (período de humor persistentemente elevado, expansivo ou irritável), e a **depressão** (período de humor predominantemente deprimido). Dados estatísticos indicam que, aproximadamente, **1 em cada 100 pessoas** pode apresentar a doença. Como várias outras doenças crônicas, o transtorno bipolar tem tratamento, e é possível ser controlado.



Em um mundo de pessoas conectadas e com grande acesso às novas tecnologias, as relações humanas também são modificadas. Sustentamos novos e antigos grupos sociais através das redes on-line e estas relações exigem do cérebro humano uma determinada capacidade para manter estes contatos.

“Nós somos criaturas sociais...”

... e redes sociais têm existido por mais de 10 mil anos. A web está sendo reconstruída, basicamente, em torno de pessoas, porque a nossa vida on-line está aproximando-se da nossa vida off-line. Daqui para frente, o comportamento social que temos evoluído ao longo dos milhares de anos será o que nos motivará a agir na web”. (Adams, 2012)



c. NIMH Life Chart adaptado para este estudo

NIMH-LCM™Clinical Ratings (RETROSPECTIVO)

Nome do paciente: _____

Período: _____ a _____

Dose mensal											
Outros:											
Outros:											
Outros:											
Tireóide (T3 ou T4):											
Benzodiazepínicos:											
Antipsicóticos:											
IMAO:											
Antidepressivo I:											
Antidepressivo II:											
Valproato:											
Carbamazepina:											
Lítio:											

Mania Disfórica											
Sintomas psicóticos											
Relacionamento amoroso											

Mania

SEVERA Totalmente incapacitado ou Hospitalizado																					
MODERADA Dificuldade evidente com atividades específicas																					
LEVE Mais energia e mais produtivo com pouco ou nenhum prejuízo funcional																					
Meses do ano																					
	1	2	3	4	5	6	7	8	9	10	11	12	Baseline								

SEVERA

MODERADA

LEVE

