



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Engenharia Elétrica

Um estudo de caso sobre o papel da Atenção Visual em uma Rede Social

Marcel Lucca Cordeiro Magalhães

Monografia apresentada como requisito parcial
para conclusão do Bacharelado em Engenharia da Computação

Orientadora

Prof.^a Dr.^a Mylène Christine Queiroz de Farias

Brasília

2016

Universidade de Brasília — UnB
Instituto de Ciências Exatas
Departamento de Engenharia Elétrica
Bacharelado em Engenharia da Computação

Coordenador: Prof. Dr. Ricardo Zelenovsky

Banca examinadora composta por:

Prof.^a Dr.^a Mylène Christine Queiroz de Farias (Orientadora) — ENE/UnB

Prof.^a Dr. Daniel Guerreiro e Silva — ENE/UnB

Prof. Dr. Marcelo Menezes de Carvalho — ENE/UnB

CIP — Catalogação Internacional na Publicação

Magalhães, Marcel Lucca Cordeiro.

Um estudo de caso sobre o papel da Atenção Visual em uma Rede Social
/ Marcel Lucca Cordeiro Magalhães. Brasília : UnB, 2016.

101 p. : il. ; 29,5 cm.

Monografia (Graduação) — Universidade de Brasília, Brasília, 2016.

1. Redes Sociais, 2. Atenção Visual, 3. Modelos de Atenção Visual

CDU 004.4

Endereço: Universidade de Brasília
Campus Universitário Darcy Ribeiro — Asa Norte
CEP 70910-900
Brasília-DF — Brasil

Dedicatória

Dedico este trabalho a minha família, que me acompanhou em toda a minha jornada de estudos, desde o início até hoje.

Agradecimentos

Agradeço a Deus, por cuidar de mim em toda minha jornada e por enviar seu Filho à Terra para trazer salvação. Aos meus pais, que sempre cuidaram de mim, providenciaram tudo que eu precisava para estudar e foram pacientes nessa caminhada. Aos meus amigos, por deixar esse tempo de faculdade mais leve e mais divertido. À Marina, minha namorada, que me inspirou a estudar e me esforçar cada vez mais através do seu exemplo.

Resumo

Redes sociais têm sido fonte de estudos sobre interações sociais, tendo desempenhado um importante papel na criação de sistemas de conteúdo distribuído. Desta forma, o estudo do comportamento de usuários nas redes sociais pode revelar não apenas como as interfaces dos ambientes dessas redes podem ser melhoradas, mas também aspectos sobre as interações sociais que podem ser utilizadas por produtores de conteúdo para melhor distribuir o conteúdo. Como as redes sociais provêm ambientes ricos no que diz respeito à quantidade de informações visuais (fotos, vídeos, gráficos, etc.), a percepção visual vai influenciar a maneira como o usuário navega. O foco deste trabalho é entender como a percepção humana e, mais especificamente, como a atenção visual afeta o comportamento de um usuário em uma rede social. Neste trabalho também estudamos a eficácia do uso de um modelo computacional de atenção visual para tentar prever esse comportamento.

Palavras-chave: Redes Sociais, Atenção Visual, Modelos de Atenção Visual.

Abstract

Social Networks have been the subject of several studies about social interactions, having played a major role in the creation of distributed content systems. The study of social network users behaviour reveal more than just how the social networks interface can be improved, but also aspects in social interaction that can be utilized for content producers to better distribute this content. In an environment that is rich of visual information (photos, videos, graphs and etc.), visual perception influences in the way that users navigate on social networks. In this study, our job is to understand how human perception and, more specifically, visual attention affect the social behaviour network users. We also study how well can a computational model of visual attention predict this behaviour.

Keywords: Social Networks, Visual Attention, Visual Attention Models.

Sumário

1	Introdução	1
1.1	Trabalhos Anteriores	2
1.2	Objetivo	3
1.3	Contribuições do trabalho	3
1.4	Organização do Trabalho	4
2	Redes Sociais	5
2.1	Facebook	6
3	Atenção Visual	9
3.1	Modelos Computacionais de Atenção Visual	10
3.1.1	Modelos de Atenção Visual Bottom-Up	12
3.1.2	Modelos Top-Down	13
3.2	Equipamentos para Rastreamento do olhar	15
4	Metodologia	17
4.1	Eye-Tracker	17
4.2	Experimento	18
4.3	Aquisição de dados experimentais	20
5	Análise dos dados experimentais	23
5.1	Análise do número de Clicks	23
5.2	Ánalyse dos mapas de saliência obtidos experimentalmente	24
5.2.1	Capturas de tela, fixações e mapas de saliência	25
5.2.2	Proporção entre áreas salientes e as áreas do Facebook	26
5.3	Comparação entre clicks e áreas salientes	28
5.3.1	Comparação dos mapas	29
5.3.2	Fixações anteriores aos clicks	32
6	Conclusão	36
	Referências	38

Lista de Figuras

2.1	Captura de tela de página do Facebook (acessada em 28/11/2015).	7
3.1	Diagrama esquemático do cérebro humano. Fonte: Instituto Nanocell, 2016.	10
3.2	Diagrama esquemático do olho humano. Fonte: Wikipedia, 2016.	11
3.3	Imagem ilustrando como ocorre o processo de foveamento, onde a fóvea foca o olho da jovem [17].	11
3.4	Exemplos de imagens (esquerda) e os seus respectivos mapas de saliência (direita) gerados utilizando o algoritmo <i>bottom-up</i> de Itti [26].	13
3.5	Esquemático de funcionamento do modelo computacional <i>bottom-up</i> GBVS.	14
3.6	Exemplo de funcionamento do modelo GBVS [40].	14
3.7	Imagem do Eye-Tracker utilizado.	16
4.1	Posicionamento do usuário durante o experimento. O Eye-tracker é montado na parte inferior do monitor e o participante se posiciona à frente do monitor, com uma distância dos olhos para o monitor que varia de 45 a 75 cm.	19
4.2	Processo de calibração do <i>eye-tracker</i> “The Eye Tribe Tracker” [54].	20
4.3	Máscaras binárias de classificação das regiões de interesse nas páginas do Facebook.	22
5.1	Dados Coletados	26
5.2	Dados Coletados	27
5.3	Exemplo de uma comparação de mapas subjetivos e objetivos que obteve um AUC de valor alto.	30
5.4	Exemplo de uma comparação de mapas subjetivos e objetivos que obteve um AUC de valor baixo.	31
5.5	Fixações antes de click em uma foto no feed de notícias.	33
5.6	Fixações antes de click no chat.	34
5.7	Fixações antes de click na notificação.	35

Lista de Tabelas

4.1	Especificações do <i>eye-tracker</i> “The Eye Tribe Tracker” [54].	18
5.1	Porcentagem de clicks por recurso da página do Facebook.	24
5.2	Listagem dos recursos por área da página do Facebook.	25
5.3	Porcentagem de clicks por área da página do Facebook.	25
5.4	Porcentagem de visualizações por área da página do Facebook.	25
5.5	Resultado da análise de dados das proporções.	28
5.6	Tabela de resultados AUC obtidos na comparação dos mapas de saliência experimentais e os mapas de saliência objetivos obtidos com o algoritmo GBVS.	30

Lista de Abreviações

- API (Application Programming Interface) consiste em um conjunto de rotinas e padrões que um software possui para ser utilizado por um aplicativo que desejam utilizar seus serviços. [17](#)
- AUC (Area Under Roc Curve) é uma métrica de qualidade para comparação de um mapa de saliência objetivo com um subjetivo. [12](#), [29](#), [30](#)
- SDK (Software Development Kit) ferramentas disponibilizadas para que desenvolvedores externos possam utilizar melhor um software. [17](#)
- TCP (Transmission Control Protocol) protocolo que define como aplicativos podem estabelecer conexões pela rede. [17](#)

Capítulo 1

Introdução

No século XXI, as formas de relacionamento das pessoas têm se transformado continuamente. Distâncias têm sido encurtadas, vínculos fortalecidos e a possibilidade de acompanhar o dia a dia de amigos, familiares e conhecidos vem crescendo. Uma das forças por trás disso são as redes sociais, que permitem que os usuários realizem diversas atividades. Nelas, as pessoas têm a oportunidade de se socializar e compartilhar acontecimentos de sua vida. O tempo empreendido nas redes vem crescendo e, juntamente com ele, as oportunidades para a exposição de produtos e ideias.

Existe um número cada vez maior de redes sociais, com novos enfoques e novas abordagens, que têm como objetivo estreitar o relacionamento entre as pessoas. Além disso, as redes sociais podem ter um grande impacto social, político ou econômico devido ao conteúdo diverso que disponibilizam e ao tempo que os usuários dedicam a elas. Por estas razões, o estudo do comportamento dos usuários em redes sociais é necessário. Mais especificamente, é necessário compreender como as pessoas se comportam nas redes, quais atividades elas realizam e o que lhes chama a atenção. Um exemplo de uma rede social bastante popular é o Facebook. Com um número de usuários superior a 1 bilhão, o Facebook vem obtendo grande sucesso, tendo até influenciado vários eventos no mundo.

Entra em cena, então, a *atenção visual*. A *atenção visual* é um processo que busca entender o comportamento do sistema visual humano que ao observar uma cena e seleciona as com maior saliência capturando-as com mais nitidez. Diversos modelos computacionais de atenção visual tem sido propostos [26][21][30]. Usando estes modelos é possível identificar na imagem, as regiões perceptualmente mais relevantes para a visão humana. Dessa forma, é possível obter uma previsão de como o cérebro humano vai reagir a determinados estímulos. Conhecendo bem o funcionamento do processo de atenção visual, pode-se classificar as áreas de uma cena de acordo com a sua relevância visual e adequar o planejamento dos recursos computacionais.

Desta forma, para desenvolvedores das redes sociais, o entendimento do sistema visual possibilita a adaptação do produto de maneira a melhor satisfazer usuários e clientes. No

caso das empresas que utilizam as redes sociais para divulgação de produtos e serviços, é possível concentrar os anúncios em áreas mais relevantes para o usuário, otimizando desta forma os recursos.

1.1 Trabalhos Anteriores

Dada a importância do uso das redes sociais, já existem na literatura diversos trabalhos que buscam entender o comportamento dos usuários nas redes sociais. Os estudos iniciais analisavam os artefatos visíveis deixados nas redes como comentários, mensagens e publicações. O trabalho desenvolvido por Gjoka et al. [19] buscou entender o quão populares eram os aplicativos do Facebook e qual o alcance deles. Já o estudo de Viswanath [56] mediu as interações entre usuários da rede, relatando que estas decrescem com o tempo e verificando que para a maioria das pessoas, as atividades se concentram entre um número pequeno de pessoas. Também existem trabalhos que estudam comportamentos de novos usuários [9], ou como propagar produtos e realizar o marketing virtual [36] e até como medir o tamanho das redes sociais [34].

Um dos estudos inovadores nesta área foi o de Benevenuto et. al. [5], que realizou uma coleta de dados de fluxo de clicks de diversas redes sociais. Neste experimento, foram obtidos dados relativos ao tempo de navegação nas redes, os recursos utilizados pelos usuários e a interação entre os usuários. Uma peculiaridade deste estudo é que ele foi capaz de identificar as atividades "silenciosas" dos usuários como ver fotos e navegar em perfis. Para o experimento, foi utilizado um *sítio* agregador de redes sociais, onde usuários podiam entrar em redes como Orkut, MySpace e LinkedIn. No total foram coletados dados de mais de 37 mil usuários em um período de 12 dias. Este vasto número de dados permitiu criar uma base de dados confiável que já foi inclusive utilizada em vários outros trabalhos.

O trabalho de Ferreira [14] buscou relacionar o estudo de Benevenuto sobre o comportamento nas redes sociais com dados de atenção visual. Foram analisadas 240 imagens de redes sociais e estas imagens foram analisadas por um modelo computacional de atenção visual "bottom-up" para gerar mapas de saliência. Estes mapas de saliência, contendo as regiões mais relevantes das imagens, foram comparadas com os dados de *clickstream* obtidos por Benevenuto. O estudo constatou que, devido à semelhança entre os resultados obtidos e os resultados de Benevenuto, a atenção visual parece influenciar a forma com que os usuários navegam nas redes sociais.

Apesar destes trabalhos fazerem uma análise do comportamento dos usuários de redes sociais, relacionando a atenção visual na página e os dados de *clickstream*, até o nosso conhecimento, ainda não existe um estudo que utilize dados de um experimento subjetivo

com os usuários de redes sociais utilizando um rastreador de olhar (*eye-tracker*). Sabe-se que com a atenção visual é possível identificar os layouts e designs que atraem atenção das pessoas. Logo, estudar a progressão das fixações dos usuários, identificar as áreas das páginas das redes sociais que são salientes e analisar se a presença de incentivos visuais funciona como atrator da atenção são passos importantes no estudo do comportamento de usuários de redes sociais.

1.2 Objetivo

Com intuito de obter informações acerca do comportamento dos usuários nas redes sociais, neste trabalho foi realizado um experimento utilizando um rastreador de olhar (*eye-tracker*). Este dispositivo detecta a posição na tela para onde o usuário está fixando o olhar. O objetivo do experimento é acompanhar um grupo de usuários enquanto eles navegam na rede social Facebook. No experimento, os usuários navegam livremente pela rede, no ambiente controlado do laboratório. Durante a realização do experimento, coletamos dados sobre as fixações, capturas de tela e os clicks realizados pelos usuários. Também foi realizada uma análise estatística destes dados, identificando os recursos visualizados e acessados e comparando os mapas de saliência capturados pelo eye-tracker e os mapas de saliência calculados utilizando um modelo computacional.

1.3 Contribuições do trabalho

Neste trabalho obtivemos:

- Dados de clicks dos usuários nos recursos do Facebook;
- Mapas de saliência subjetivos de páginas do Facebook, ou seja, mapas capturados por um *Eye-Tracker* (rastreador de olhar) em um experimento com participantes voluntários;
- Mapas de saliência objetivos de páginas do Facebook, ou seja, mapas gerados por um modelo computacional de atenção visual;
- Estatísticas sobre as fixações dos olhares dos usuários nas diversas regiões de interesse do Facebook;
- Análise de desempenho dos mapas de saliência objetivos em comparação com mapas de saliência subjetivos.

Em suma, o objetivo deste trabalho é analisar o comportamento dos usuários da rede social Facebook através do monitoramento das fixações do seu olhar e das suas ações (clicks). O

estudo permite analisar regiões ou áreas da página do Facebook que foram mais salientes e a sucessão de clicks para cada uma destas regiões. Os resultados foram comparados com um modelo computacional de atenção visual *bottom-up* capaz de estimar as áreas salientes das capturas de tela do Facebook, de acordo com as propriedades intrínsecas da cena (contraste, cor, orientação, etc).

1.4 Organização do Trabalho

O trabalho está dividido em seis capítulos. Nos Capítulos 2 e 3 são introduzidos os temas redes sociais e atenção visual, respectivamente. Em seguida, no Capítulo 4 apresentamos a metodologia utilizada no trabalho. No Capítulo 5, detalhamos os resultados coletados. Finalmente, no Capítulo 6, são apresentadas as considerações finais do trabalho.

Capítulo 2

Redes Sociais

O termo rede social normalmente se refere a uma estrutura virtual que possibilita a conexão entre pessoas para troca de informações. Na literatura existe uma série de definições. Uma das mais consistentes é a dada por Boyd e Ellison [2007], que afirma que os *sítios* de redes sociais são serviços web que permitem:

- criar perfis em um sistema;
- articular conexões com outros usuários; e
- ver e navegar pelas próprias listas de conexões e as de outros usuários.

Desde o início da Internet, já estavam em formação *sítios* que possuíam esse padrão de características e que buscavam promover uma troca de informações entre as pessoas. O primeiro serviço que se encaixou mais claramente no conceito de rede social foi o *sixdegrees.com*, que surgiu nos Estados Unidos em 1997. Ele foi criado por Andrew Weinreich e teve como base a teoria dos seis graus, desenvolvida por Stanley Milgram em seu artigo “The Small World Problem” [11]. A teoria dos seis graus diz que, em média, entre duas pessoas são necessários apenas cinco intermediários para estabelecer uma relação entre elas [39]. Com isso em mente, Weinreich procurou desenvolver um *sítio* que mostrava essas relações. O *sixdegrees.com* foi o primeiro *sítio* a possibilitar aos usuários criar perfis, mostrar sua lista de amigos e navegar na lista dos outros. O *sítio* chegou a alcançar um alto número de usuários, mas acabou fechando as portas em 2000 por não conseguir se tornar rentável e, talvez, por prestar um serviço um pouco à frente do seu tempo [22].

Nos anos seguintes, um número cada vez maior de redes sociais foram surgindo com diversos propósitos, características e funções. Muitas destas redes sociais obtiveram sucesso. Um exemplo é a Friendster, que surgiu para competir com o Match.com, um *sítio* usado para marcar encontros amorosos. O Friendster ampliou o objetivo do Match.com,

permitindo interconexões com outros interesses. Desta forma, surgiram vários grupos de usuários com o mesmo interesse no Friendster e as pessoas começaram a usá-lo como forma de divulgação de serviços, propaganda de produtos, recrutamento para empresas e diversas outras formas [6]. O *sítio*, cresceu em utilização e chegou a ser a rede social mais utilizada nos Estados Unidos até ser ultrapassado pelo MySpace. O Friendster teve um declínio em uso na América do Norte, mas cresceu em utilização na Ásia. Em 2011, o Friendster se tornou uma rede de social de jogos e permaneceu em funcionamento até junho de 2015.

No contexto brasileiro, a primeira rede social de sucesso foi o Orkut. Ele foi lançado em 2004, pelo Google, e teve como criador o engenheiro turco Orkut Buyukkokten [45]. Seguindo o tipo de serviço oferecido pelo Friendster, conforme descrito no artigo de Milgram [39], o Orkut chegou a ser a rede social dominante no Brasil, até ser ultrapassada pelo Facebook. Ele permitia as mesmas funcionalidades do Friendster ao criar uma rede com perfis, comunidades e usuários. Em contrapartida, o Orkut tinha páginas com formato menos rígido, o que permitia que o usuário pudesse construir um perfil que melhor o representasse.

Atualmente, há diversas redes sociais disponíveis, sendo que várias destas redes têm objetivos específicos. Alguns exemplos de redes específicas são o Instagram, cujo foco é o compartilhamento de fotos e vídeos, e o Twitter, que tem como objetivo a distribuição de mensagens curtas [44]. Ambas apresentam uma oportunidade de se conectar ou acompanhar as pessoas, sejam elas amigos ou familiares próximos ou famosos distantes [3]. Também é comum usar essas redes para obter notícias [47]. Um fato inovador nas redes sociais é que não é necessária uma reciprocidade no relacionamento [43]. Vale salientar que, apesar de serem muito utilizadas, as redes sociais não possuem recursos disponíveis para uma análise mais detalhada ou uma forma de navegação diversificada. O seu conteúdo é concentrado nas publicações e atualizações dos usuários, o que facilita as análises da atenção visual.

2.1 Facebook

O Facebook foi criado em 2004 por alunos da Universidade de Harvard. Ele tinha como objetivo permitir que os alunos da instituição pudessem se relacionar. Na época, o acesso ao Facebook era restrito, ou seja, para se vincular ao Facebook era necessário possuir um e-mail vinculado à instituição [12]. Mantendo esta característica de acesso restrito, o Facebook rapidamente se expandiu para outras universidades. Graças ao seu grande sucesso, o Facebook foi abrindo portas para instituições de ensino médio em 2005, depois para empresas em 2006 [58], até finalmente se tornar disponível para o público em

geral no final deste mesmo ano. Um exemplo de uma página do Facebook é apresentado na Figura 2.1.

Atualmente, o Facebook é a rede social mais popular do planeta e possui um alto número de usuários. Até junho de 2015, o Facebook possuía 1,49 bilhões de usuários ativos, sendo que, em média, 968 milhões de usuários se conectam por dia, de acordo com dados do próprio Facebook. Segundo pesquisa feita pelo Pew Research Center em 2013, 71% dos usuários da Internet americanos possuem uma conta no Facebook. Outro dado que mostra a influência desta rede social é que, no ranking Alexa que classifica os *sítios* baseados no tráfego [31], o Facebook é o segundo *sítio* mais acessado no mundo. Sabe-se que cada usuário passa aproximadamente 20 minutos por dia no Facebook e $\frac{2}{3}$ dos usuários se conectando diariamente [32]. Hoje, o Facebook possui um perfil de utilização bastante diverso, que inclui comunicação individual direta, o consumo passivo de notícias sociais e a difusão de informações [8]. O Facebook também é frequentemente utilizado na política [20] e na educação [15]. A importância desta rede social foi demonstrada pela grande influência que ela teve sobre recentes acontecimentos históricos, como revoltas políticas e eleições. O Facebook também é usado para divulgar informações sobre desastres naturais e acidentes [33].



Figura 2.1: Captura de tela de página do Facebook (acessada em 28/11/2015).

O Facebook possui vários recursos [50]. A comunicação pode ocorrer via mensagens ou publicações (*posts*). Os *posts* podem conter textos, fotos ou vídeos e ter caráter público ou restrito a alguns grupos de usuários. Além disso, os *posts* podem ser feitos por meio de uma atualização do status ou da *timeline* do usuário. Abaixo dos posts existe uma seção em que outros usuários podem fazer comentários. Aos usuários que querem mostrar aprovação por um *post*, existe o recurso curtir (*like*). Cada usuário tem à sua disposição um *feed* de notícias onde ele vê uma seleção dos *posts* de seus amigos, páginas curtidas e anúncios comerciais. Existe também a possibilidade de criar grupos e eventos no Facebook para

aglomerar usuários em torno de um determinado interesse em comum. Outras aplicações ou serviços do Facebook incluem jogos, bate-papo (*chat*), notas e diversos aplicativos.

O Facebook permite aos usuários a criação de perfis ou de páginas. Os perfis são normalmente utilizados para uso individual do usuário e dos seus amigos. As páginas funcionam como uma espécie de blog, que é utilizado por grupos ou empresas para permitir aos usuários um relacionamento mais próximo com estas empresas, suas atividades e os seus produtos. Por exemplo, na própria página da empresa Facebook, o usuário (ou cliente) pode interagir com a empresa [41].

O recurso anúncios do Facebook é utilizado por empresas que desejam divulgar sua marca. Primeiro, as empresas criam uma página gratuitamente e, por meio dessa página, elas podem criar anúncios patrocinados e promover estes anúncios para uma esfera específica de usuários [7]. Ou seja, o Facebook permite identificar os usuários desejados pelo perfil de forma a permitir que a empresa faça a divulgação direcionada a eles. Dentre as possíveis formas de anúncios, as que têm destaque para os usuários são aquelas que aparecem no *feed* de notícias [47].

Neste trabalho, o foco é estudar o comportamento médio de um usuário em uma sessão de navegação no Facebook. O nosso objetivo é analisar quais as regiões da página do Facebook melhor captam a atenção do usuário. Também nos interessa saber como a saliência das regiões afeta a navegação (ou seja, os clicks). Desta forma, no próximo capítulo, damos uma breve introdução aos sistema visual humano e aos modelos de atenção visual.

Capítulo 3

Atenção Visual

Por meio dos sentidos, o corpo humano recebe uma inúmera quantidade de informações. Uma forma de entender esse funcionamento é que cada um dos sentidos passa estímulos que são transportados até o cérebro, que funciona como uma espécie de computador [52].

No caso da visão, o caminho da informação começa na retina, onde as informações visuais são inicialmente recebidas pelos fotorreceptores. Os fotorreceptores transformam a luz em sinais elétricos, possibilitando que estes transitem pelo nervo óptico. Os nervos passam o sinal para o tálamo até chegarem ao córtex visual [24]. Ao serem recebidas no córtex visual, a informação visual segue dois caminhos. Um deles é o do córtex parietal posterior, que trata da localização espacial e do direcionamento da atenção visual. O outro caminho é o do córtex inferotemporal, que cuida do reconhecimento e da identificação dos estímulos [25]. Finalmente essas informações se reúnem no córtex pré-frontal, que determina os próximos movimentos dos olhos. De forma geral, mais atenção é dada às áreas salientes da cena ou às áreas de interesse do observador, o que garante um processamento mais eficiente das informações capturadas. A Figura 3.1 apresenta uma ilustração do cérebro humano e das partes que o compõem.

O direcionamento do olhar humano é importante devido às características específicas da fóvea. Mais especificamente, movimentos sacádicos direcionam o eixo visual para mudar as fixações de forma que a região central do olhar (foco) seja direcionada para a fóvea, uma área de alta resolução na retina que é circundada por uma área de baixa resolução. Ou seja, ao direcionar o olhar às áreas mais salientes, estas áreas são capturadas na região da fóvea (com maior resolução), enquanto que as regiões consideradas menos salientes são capturadas por outras regiões (com menor resolução). Na Figura 3.2 [1] temos uma imagem mostrando as partes do olho humano. Na Figura 3.3 é apresentada uma simulação de como uma imagem seria representada na retina, onde consideramos que o observador está fixando o olhar no olho da jovem. O desafio apresentado aos modelos

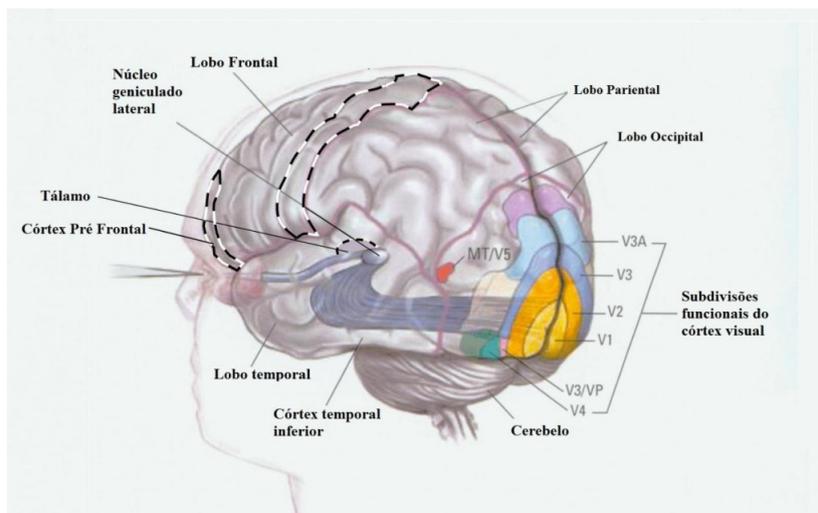


Figura 3.1: Diagrama esquemático do cérebro humano. Fonte: Instituto Nanocell, 2016.

de atenção visual é como representar os diversos processos do sistema visual humano [23].

Como já mencionado anteriormente, o volume de informações captadas pelo olho é muito grande. Para processar melhor essas informações, o cérebro utiliza a atenção seletiva. Em 2006, Rossini e Galera [48] definiram atenção seletiva como “a capacidade mental de selecionar apenas uma pequena parcela da informação contida no ambiente em detrimento da grande quantidade de estímulos disponíveis ao nosso redor.” Desta forma, a atenção visual é o processo por meio do qual o cérebro seleciona áreas que se destacam no campo visual de maneira a dar maior relevância a estas áreas, em detrimento de outras regiões da cena. Os processos de atenção visual são classificados em dois tipos. O primeiro tipo se chama *bottom-up* e leva em consideração apenas as características intrínsecas da cena. Este mecanismo leva em torno de 20 a 50 ms para detectar as áreas mais salientes em uma imagem. O segundo tipo de mecanismo de atenção visual é denominado de *top-down*. Este tipo de mecanismo leva em consideração informações semânticas da cena, a tarefa que está sendo realizada pelo operador, além de aspectos cognitivos. Naturalmente, este mecanismo é mais lento, levando cerca de 200 ms [51].

3.1 Modelos Computacionais de Atenção Visual

Para detecção das áreas salientes de uma imagem, foram desenvolvidos vários modelos computacionais [26][21][30]. A maioria destes modelos gera mapas de saliência, que identificam as regiões da imagem que são consideradas mais relevantes (ou salientes). As imagens dos mapas de saliência utilizam uma representação em escala cinza, na qual quanto maior a intensidade do pixel (mais claro), maior a saliência deste pixel. De acordo

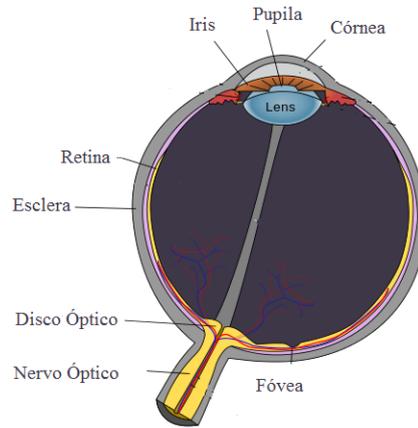


Figura 3.2: Diagrama esquemático do olho humano. Fonte: Wikipedia, 2016.

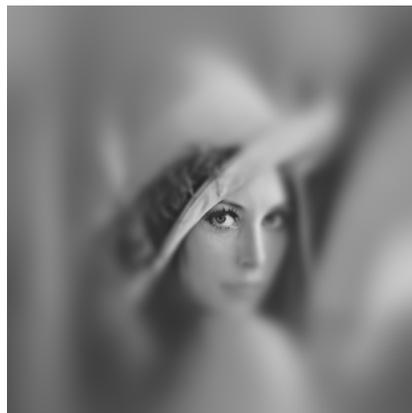


Figura 3.3: Imagem ilustrando como ocorre o processo de foveamento, onde a fóvea foca o olho da jovem [17].

com a classificação dos mecanismos de atenção visual existem modelos computacionais *bottom-up* e *top-down* [10].

3.1.1 Modelos de Atenção Visual Bottom-Up

Os modelos de atenção visual *bottom-up* identificam a atenção involuntária causada pelas características intrínsecas do sinal [2]. Por exemplo, ao olharmos uma tela totalmente branca com um ponto vermelho, nosso olhar é naturalmente atraído para este ponto vermelho devido às características da região que apresenta um grande contraste de cor [35]. Ou seja, áreas que se destacam nas imagens, seja por causa de um formato específico, pela presença de padrões quebrados, ou um contraste de cores geram um estímulo rápido e involuntário, direcionando nossa atenção.

Um exemplo de um modelo *bottom-up* é o algoritmo desenvolvido por Itti et al. [26]. Esse algoritmo realiza uma decomposição da imagem em várias escalas e processa separadamente as regiões da imagem em cada escala, analisando as suas características de cor, intensidade e orientação. Em seguida, os mapas de atributos de cada uma das características são combinados, gerando um mapa de saliência final que representa as áreas mais salientes da imagem com valores de intensidades altos (mais claros). A Figura 3.4 apresenta um conjunto de exemplos de imagens (esquerda) e os seus respectivos mapas de saliência em tons de cinza (direita) gerados utilizando o algoritmo de Itti.

Outro modelo *bottom-up* disponível na literatura é o Graph-Based Visual Saliency (GBVS) desenvolvido por Harel et al. [21], em 2006. O GBVS é um modelo *bottom-up* que utiliza algoritmos baseados em grafos, obtendo resultados bastante satisfatórios. O algoritmo GBVS possui três etapas, ao final das quais são gerados os mapas de saliência. As etapas são as seguintes:

1. O algoritmo gera mapas de atributos através de uma filtragem linear. Desta forma são extraídos vetores de características das imagens.
2. É realizada a ativação dos mapas de saliência usando a distribuição de probabilidade de equilíbrio de uma cadeia Markoviana nos vetores de características.
3. É realizada a combinação dos mapas ativados, usando uma cadeia Markoviana.

Na Figura 3.5 é apresentado o diagrama de blocos do algoritmo do modelo GBVS, enquanto que na Figura 3.6 é apresentado um exemplo de funcionamento do modelo. Em um experimento no qual 39 pessoas observaram 300 imagens e tiveram suas fixações coletadas, os modelos GBVS e Judd [29] obtiveram os melhores resultados de acordo com a métrica “Area Under Roc Curve” (AUC) [30]. De posse dos mapas de saliência subjetivos (gerados pelas fixações dos participantes) e dos objetivos (gerados pelo modelo computacional GBVS), podemos comparar o desempenho dos dois tipos de modelos.

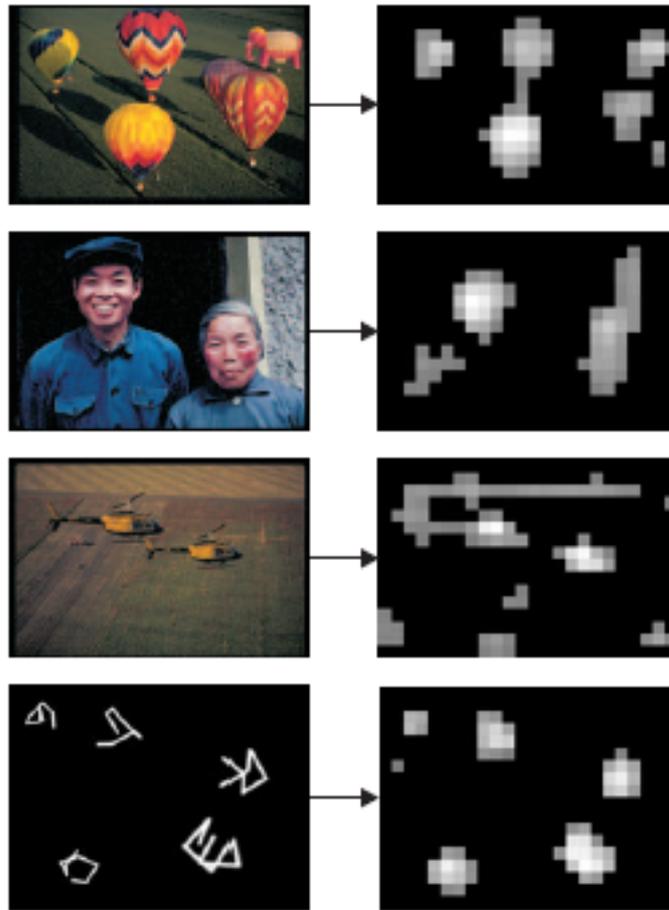


Figura 3.4: Exemplos de imagens (esquerda) e os seus respectivos mapas de saliência (direita) gerados utilizando o algoritmo *bottom-up* de Itti [26].

3.1.2 Modelos Top-Down

Uma outra forma de analisar a atenção visual é usando modelos de atenção visual *top-down*. Esses modelos levam em conta as tarefas realizadas pelo observador, o contexto, as suas expectativas e outros fatores cognitivos que afetam o comportamento humano [57]. Por exemplo, quando uma pessoa procura um conhecido em uma foto, os seus olhos são atraídos por rostos. Ou ainda, quando um motorista procura as chaves do carro, a sua atenção é atraída por objetos metálicos pequenos. Algoritmos de atenção *top-down* são mais complexos do que os *bottom-up*, devido à dificuldade de estimar o contexto semântico da cena ou ainda o contexto do observador.

Um exemplo de modelo computacional *top-down* é o modelo desenvolvido por Judd [30]. Este modelo combina características de alto nível (*top-down*), de médio e baixo níveis (*bottom-up*) para obter um mapa de saliência utilizando técnicas de aprendizado de máquina. Em outras palavras, o modelo Judd combina vários modelos de atenção visual com a ajuda de dados experimentais e aprendizado de máquina. Para obtenção das

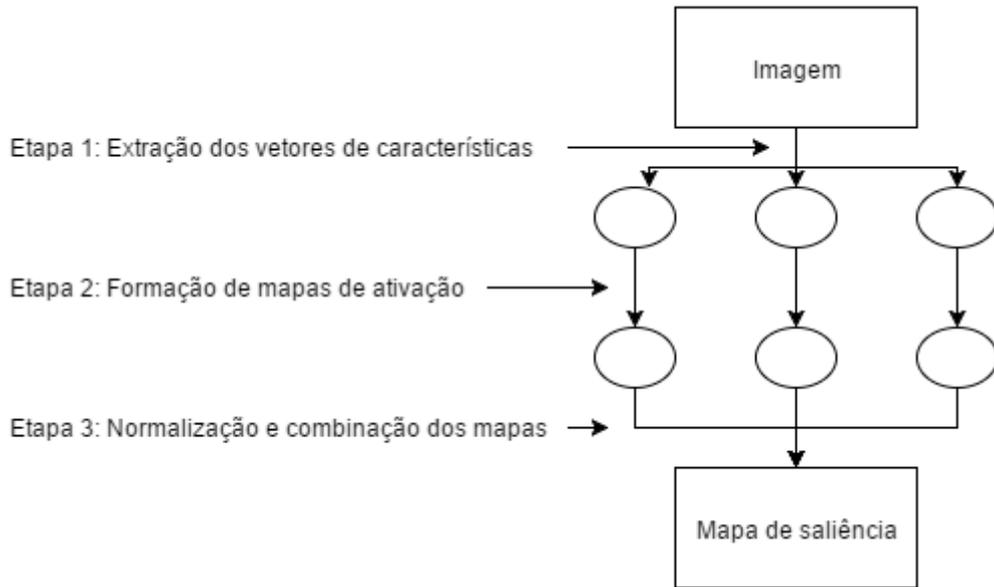
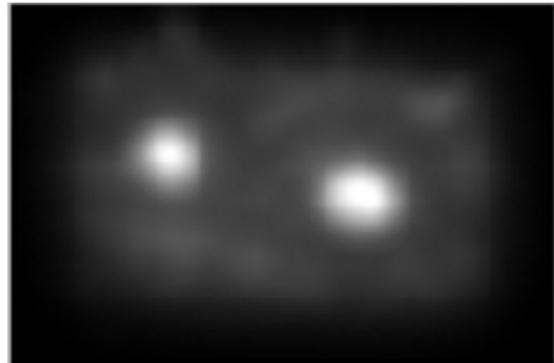


Figura 3.5: Esquemático de funcionamento do modelo computacional *bottom-up* GBVS.



(a) Imagem Original.



(b) Mapa de saliência gerado pelo modelo GBVS.

Figura 3.6: Exemplo de funcionamento do modelo GBVS [40].

características de baixo nível são utilizados os modelos de Itti [25] e de Torralba [53]. Uma das características de nível médio é o modelo de detecção do horizonte, que é uma das regiões da cena onde as pessoas tendem a fixar o olhar [49]. Além disso, o modelo também utiliza um algoritmo de detecção do centro da tela, também uma região que atrai o olhar humano. Para as informações de alto nível foram usados o famoso modelo de detecção de faces de Viola e Jones [55] e um detector de pessoas e carros desenvolvido por Felzenszwalb [13]. Como já citado, o modelo Judd apresenta um alto desempenho. Porém, este modelo é bem mais lento que os modelos *bottom-up*, o que dificulta sua aplicação práticas [42].

3.2 Equipamentos para Rastreamento do olhar

Os rastreadores de olhar (*Eye-trackers*) são dispositivos que permitem identificar os focos de atenção de um observador humano. Utilizando este tipo de dispositivo, pesquisadores têm realizado pesquisas na área de atenção visual há um longo tempo. O primeiro estudo na área foi feito por Louis Émile Javal no final do século XIX. Javal observou o movimento dos olhos das pessoas ao lerem e percebeu a ocorrência de sacadas [4]. Sacadas são movimentos dos olhos que direcionam a fóvea para regiões de interesse. Nesta época, os experimentos estavam restritos à observação visual. Posteriormente, foram surgindo outros tipos de *eye-tracking*, que eram mais precisos, mas estes métodos possuíam como desvantagem a necessidade de estar em contato direto com a córnea. Em 1901, Dodge e Cline desenvolveram o primeiro método não invasivo de *eye-tracking*, que utilizava fotografias para marcar o movimento dos olhos [27]. Essa técnica inovadora mudou a tônica dos experimentos de *eye-tracking* realizados até 1970. Nesse período, houve um grande avanço tanto na área de psicologia e, mais especificamente, no estudo do sistema visual humano. Além disso, neste período foram desenvolvidas tecnologias que permitiram o desenvolvimento de *eye-trackers* [46] mais precisos e menos invasivos. Gradativamente a tecnologia evoluiu, até que em 1988 criou-se o primeiro *Eye-tracker* para uso com computador PC produzido pela empresa LC Technologies (EUA) [4]. Desde então, cada vez mais *Eye-trackers* são lançados no mercado, o que permite sua utilização não apenas para pesquisa, mas também para aplicações de uso comercial [4].

Atualmente, há três tipos de tecnologias utilizadas em *Eye-trackers* [28]:

- a. Tecnologia mecânica: Uma lente é colocada em contato com o olho e, por meio dos movimentos dela, é feito o rastreamento do olhar. Estas técnicas costumam ser mais precisas, porém são mais incômodas para os usuários por gerar possíveis irritações no olho e aumentar o número de piscadas.
- b. Tecnologia com eletrodos: O diferencial de potencial elétrico é medido através de eletrodos colocados perto do olho. É uma tecnologia bem barata, contudo não tão precisa.
- c. Tecnologia de observação: Esta tecnologia utiliza uma câmera que é acoplada a um equipamento. A câmera captura a face do observador e técnicas de processamento de imagens são utilizadas para analisar e identificar regiões do olho e estimar a posição da tela para onde o olhar está fixado. O olho é identificado utilizando apenas as suas características visíveis. Esse método é bem prático e facilmente reproduzido fora de um ambiente de laboratório.

Neste trabalho, utilizamos um eye-tracker que utiliza a tecnologia de observação. O eye-tracker, fabricado pela empresa The Eye-Tribe, é o modelo The Eye-Tribe Tracker e possui acurácia visual entre $0,5^\circ$ e 1° . A Figura 3.7 apresenta uma foto deste eye-tracker. Observe que este é um equipamento pequeno, que não causa nenhum desconforto ao usuário, o que é importante para o tipo de experimento que estamos realizando. Além disso, apesar de a precisão do equipamento estar abaixo da precisão de modelos profissionais, esta precisão é suficiente para a aplicação em questão. O próximo capítulo fornece maiores detalhes sobre o eye-tracker e o experimento realizado neste trabalho.



Figura 3.7: Imagem do Eye-Tracker utilizado.

Capítulo 4

Metodologia

Neste trabalho fizemos um experimento para coletar dados sobre as fixações dos olhares de usuários no Facebook. Neste capítulo é mostrado como se desenvolveu o experimento, desde o *eye-tracker* utilizado até a preparação dos participantes do experimento. Aqui é apresentado os tipos de dados que coletamos e utilizamos nas análises, que são:

- Dados de clicks nos recursos do Facebook;
- Mapas de saliência subjetivos, ou seja, mapas gerados por um *Eye-Tracker* (rastreador de olhar);
- Mapas de saliência objetivos, ou seja, mapas gerados por um modelo computacional de atenção visual;
- Máscaras das regiões de interesse do Facebook.

4.1 Eye-Tracker

O *eye-tracker* utilizado no experimento é o “The Eye Tribe Tracker” [54]. Este *eye-tracker* é de uso comercial e possui um sensor de luz infravermelha que rastreia os movimentos da pupila, retornando as coordenadas observadas. Feito para desenvolvedores, ele já possui uma **SDK** e uma **API** que permitem a criação das aplicações. Como parte do nosso trabalho, desenvolvemos uma aplicação que realiza uma conexão, entre o servidor do *eye-tracker* e o computador com o qual ele está conectado, utilizando um socket **TCP**. Através desta conexão **TCP** os quadros que contêm as informações relativas às fixações do olhar são recebidos pelo computador. Estes quadros contêm as coordenadas das fixações do usuário.

A precisão do *eye-tracker* permite um ângulo visual de 0.5 grau em média. Devido a esse ângulo, quando utilizado dentro do alcance de rastreamento, as coordenadas da

Tabela 4.1: Especificações do *eye-tracker* “The Eye Tribe Tracker” [54].

Taxa de Amostragem	30Hz ou 60 Hz
Acurácia visual	0,5° - 1°
Resolução Espacial	0,1° (RMS)
Latência	<20 ms a 60Hz
Calibração	9, 12 ou 16 pontos
Alcance de Rastreamento	45 - 75 cm
Área de Rastreamento	40 X 30 cm a 65 cm de distância (30Hz)
Tamanho da Tela	Até 24 polegadas
API/SDK	C++, C# e Java

fixação podem ter um desvio máximo de 10 mm. Os detalhes das especificações do *eye-tracker* são apresentados na Tabela 4.1.

4.2 Experimento

Um total de 28 participantes voluntários realizaram o experimento que consistiu em navegar na sua conta do Facebook por um período de 8 a 10 minutos. O experimento foi realizado no laboratório em uma sala isolada, onde os participantes tiveram privacidade para navegar livremente. O objetivo foi gerar uma situação mais próxima do uso cotidiano de redes sociais. Enquanto os participantes navegavam, as suas fixações foram monitoradas por um *eye-tracker*. Também foram armazenados os clicks feitos pelos participantes durante a navegação.

O experimento foi realizado com 28 pessoas com idades entre 18 e 32 anos. Foi permitido que participantes que necessitavam de óculos que os mantivessem durante o experimento. As calibrações do *eye-tracker* ocorreram com sucesso. Verificou-se que participantes com olhos irritados não poderiam fazer o experimento até que a irritação passasse. Tivemos participantes com olhos de diversas cores e, curiosamente, o *eye-tracker* obteve resultados mais precisos para participantes de olhos claros do que para participantes com os de olhos escuros.

Dos 28 participantes, quatro deles foram descartados devido ao *eye-tracker* perder, por várias vezes, a fixação do seu olhar, retornando fixações atípicas. Isto ocorreu possivelmente por uma mudança postural do participante, incluindo um desvio do olhar ao abaixar a cabeça para digitar.

Durante o experimento, os participantes foram posicionados em uma cadeira em frente ao monitor, conforme ilustrado na Figura 4.1. Os olhos dos participantes ficaram a uma distância de 45-75 cm da tela. Quando o usuário usava óculos, em alguns poucos casos foi necessário removê-los para a realização do experimento. O *eye-tracker* foi posicionado

imediatamente embaixo da tela do monitor direcionado para os olhos do indivíduo. Durante o experimento, o experimentador instruiu os participantes a não se movimentarem muito de forma a não prejudicar a captura de fixações de olhar feita pelo *eye-tracker*. Nenhum suporte de cabeça foi utilizado para manter a naturalidade do experimento.

Para coletar as informações, a aplicação desenvolvida se conecta ao servidor do *eye-tracker* e envia sinais chamados de batimentos, que são responsáveis por manter a conexão ativa. A cada batimento são obtidas 10 fixações do participante. Quando o batimento chega no servidor, uma captura de tela é feita. Uma segunda aplicação foi desenvolvida com o objetivo de coletar os clicks. Quando um click é detectado uma interrupção, é gerada e obtemos as coordenadas do click e o instante em que ele aconteceu. Os códigos relativos às aplicações encontram-se em um repositório na plataforma Github [37].

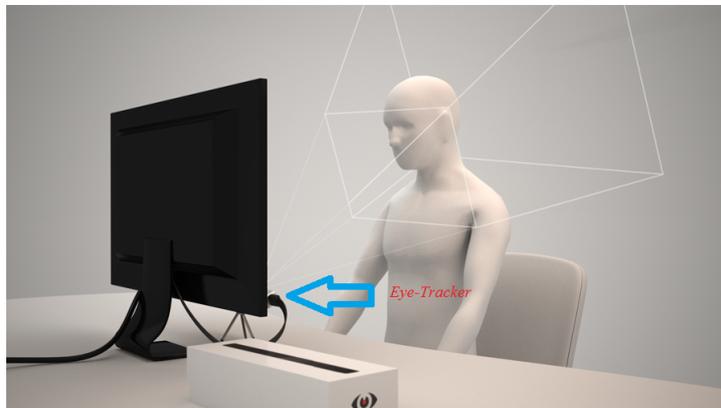
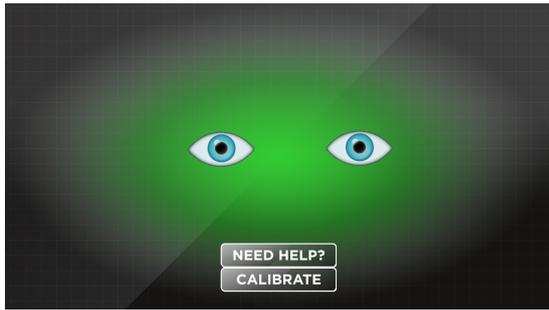
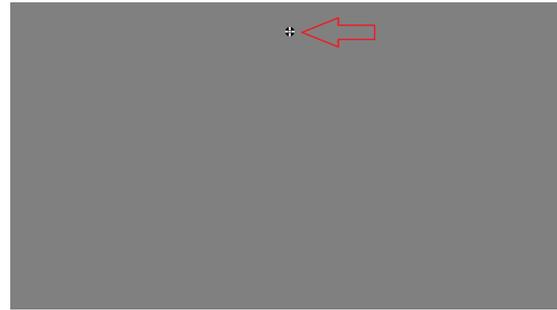


Figura 4.1: Posicionamento do usuário durante o experimento. O Eye-tracker é montado na parte inferior do monitor e o participante se posiciona à frente do monitor, com uma distância dos olhos para o monitor que varia de 45 a 75 cm.

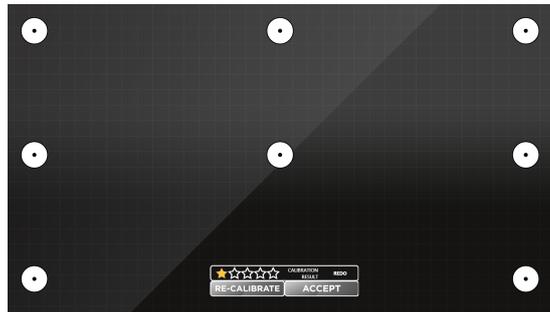
A primeira etapa do experimento consiste na calibração do *eye-tracker*, que é realizada por um software fornecido pelo próprio fabricante. A Figura 4.2 mostra as diversas etapas realizadas no processo de calibração. Terminada a calibração do *eye-tracker*, os softwares são inicializados e o experimento começa. Nesse processo, primeiramente são detectados os olhos do usuário e, em seguida, o participante deve seguir com os olhos um círculo que aparece na tela. Em seguida, a eficácia da calibração é testada pedindo que o usuário direcione o olhar para algum dos círculos brancos que aparecem na tela, como ilustrado na Figura 4.2(c). De acordo com a precisão obtida, o software dá uma nota de 1 a 5 ao processo de calibração. Caso a calibração esteja correta o *eye-tracker* consegue detectar a posição da fixação do olhar e o círculo se torna vermelho. Caso a nota da calibração seja inferior a 4, uma nova calibração é realizada. Como já enfatizado, a tarefa do participante se resume em navegar no Facebook por pelo menos 8 minutos e no máximo 10 minutos. O usuário foi instruído a não entrar em outras páginas da Internet e não assistir vídeos longos durante o experimento.



(a) Captura de tela do procedimento de localização dos olhos do participante.



(b) Captura de tela mostrando o círculo que o participante deve seguir com os olhos para calibrar o *eye-tracker*.



(c) Captura de tela mostrando o teste de calibração. O participante deve focar em um dos círculos que, caso a calibração tenha tido sucesso, deverá se tornar vermelho.

Figura 4.2: Processo de calibração do *eye-tracker* “The Eye Tribe Tracker” [54].

4.3 Aquisição de dados experimentais

Para identificar as regiões que os participantes observaram em cada fixação, as capturas de tela daquele instante são combinadas com posições das fixações coletadas pelo *eye-tracker*. Isto é feito da seguinte maneira. Primeiramente, as posições das fixações são representadas pelas coordenadas do pixel correspondente e estas coordenadas são representadas como pontos brancos em uma imagem completamente preta. Em seguida, utiliza-se um filtro Gaussiano para filtrar esta imagem gerando uma nuvem de pontos em torno de cada ponto. Esta imagem é então multiplicada pela captura de tela, gerando uma simulação de uma imagem foveada. Ao mesmo tempo, são também gerados mapas de saliência objetivos utilizando o modelo computacional de atenção visual Graph-Based Visual Saliency (GBVS) [21]. Os mapas de saliência gerados com o modelo computacional são conhecidos como mapas de saliência objetivos.

Em seguida, analisou-se a utilização dos recursos do Facebook (fotos, *posts*, vídeos, chat) pelos usuários, fazendo uma comparação do número de clicks realizados pelos usuários em cada recurso e do número de vezes que o usuário fixou o olhar na área de interesse

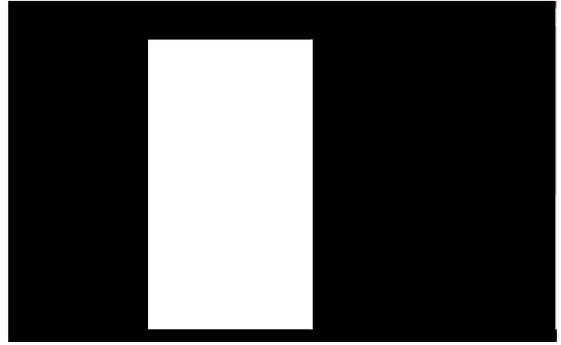
em que determinado recurso se encontra. Para determinar o número de vezes que o usuário fixou o olhar em cada região de interesse são utilizadas máscaras binárias de classificação das páginas.

As máscaras binárias de saliência foram construídas utilizando um layout da página do Facebook no qual identificou-se as diferentes regiões onde se encontravam os diversos recursos utilizados pelo usuário. Na Figura 4.3, são ilustradas as máscaras binárias de classificação das regiões de interesse na página do Facebook. Por exemplo, para identificar o *feed* de notícias construímos uma matriz que tem valor “1” na região que corresponde ao *feed* de notícias e valor “0” no resto da imagem (ver Figura 4.3 (b)). Da mesma forma, uma máscara binária de saliência é gerada, na qual o valor “1” é atribuído aos pixels nos quais o usuário fixou o olhar pelo menos uma vez e “0” aos pixels restantes. Analisou-se os mapas de saliência obtidos experimentalmente, calculando a área total do mapa de saliência, a área total das regiões de interesse do usuários e a área total das capturas de tela. Estas análises foram realizadas utilizando o software Matlab.

Foram realizadas análises sobre os mapas subjetivos de modo a ver a porcentagem das regiões de interesse do Facebook salientes. As regiões de interesse foram representadas por máscaras binárias, dessa forma analisamos o quanto das máscaras foi saliente para os usuários. Finalmente, foi realizada uma comparação entre os mapas de saliência subjetivos e os objetivos para ver a eficácia do modelo GBVS na estimação das áreas salientes da página do Facebook. No próximo capítulo, são apresentadas as análises dos experimentos.



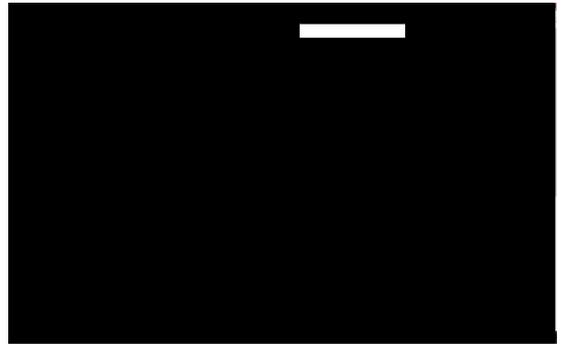
(a) Máscara binária relativa à região do chat.



(b) Máscara binária relativa à região do *feed* de notícias



(c) Máscara binária relativa à região de grupos, eventos e aplicativos.



(d) Máscara binária relativa à região de notificações.



(e) Máscara binária relativa à região de recomendações.

Figura 4.3: Máscaras binárias de classificação das regiões de interesse nas páginas do Facebook.

Capítulo 5

Análise dos dados experimentais

Neste capítulo, mostramos os resultados obtidos com os dados de click e fixações de olhar e das comparação dos mapas de saliência subjetivos com os mapas de saliência objetivos. No final do capítulo apresentamos alguns exemplos de navegação dos usuários antes dos clicks.

5.1 Análise do número de Clicks

Analisando os 24 usuários que realizaram o experimento, foram coletados, em média, 27 clicks por usuário. Deste número, foram desprezados os clicks que não eram relativos a alguma atividade no Facebook. Por exemplo, foram detectadas várias vezes o uso de clicks para fechar tarefas e *posts*. O número total de clicks foi baixo, resultando em dois ou três clicks por minuto na atividade.

Foi, então, realizada uma análise da relação entre os clicks e os recursos utilizados pelos participantes. Foi calculada uma média de todos os clicks realizados para analisar sua distribuição em relação aos recursos. Para esse cálculo pegamos o número total de clicks e dividimos pelo número total de participantes. Obervou-se que as fotos predominaram como o recurso mais clicado, com 28% dos clicks. Em seguida, tivemos as curtidas, com 10%, e as notificações, com 8%. Não foi verificado nenhum click em anúncios de produtos em todo o experimento. A Tabela 5.1 apresenta um sumário da porcentagem de clicks recebidos pelos diversos recursos do Facebook. Na Tabela 5.2 apresentamos uma listagem dos recursos por área da página no Facebook.

Também classificamos os clicks de acordo com as regiões da página do Facebook onde estes aconteceram, utilizando máscaras binárias. A região com mais clicks foi o *feed* de notícias, acumulando mais da metade dos clicks. Ela foi seguida pelas áreas de notificações, área de grupos, eventos e aplicativos, área de *chat* e área de recomendados, respectivamente. Estes dados são na Tabela 5.3.

Tabela 5.1: Porcentagem de clicks por recurso da página do Facebook.

Recursos	Porcentagem de clicks
Fotos	28,44%
Curtidas	10,36%
Notificações	8,81%
Home	6,96%
Perfis	5,41%
Comentários	5,41%
Chat	5,41%
Eventos	4,64%
Posts	3,86%
Vídeo	3,71%
Páginas	3,4%
Amigos	3,4%
Menu	2,78%
Pesquisa	2,78%
Grupos	2,16%
Textos	2,01%
Linha do tempo	0,46%
Aplicativos	0,00%
Anúncios	0,00%

5.2 Análise dos mapas de saliência obtidos experimentalmente

Nesta seção, apresentamos as análises das regiões salientes da página do Facebook. Quando analisamos os mapas de saliência obtidos experimentalmente, de acordo com as regiões das páginas do Facebook nas quais eles estão contidos, foi possível estimar a porcentagem do tempo em que uma área foi foco da atenção do usuário. Por termos 10 fixações por mapa de saliência, é possível que um usuário focasse o olhar em várias áreas em um mesmo mapa. Verificamos então que a área do *feed* de notícias foi a que mais recebeu a atenção do usuário, seguida da área de grupos, eventos e aplicativos e da área de recomendados. Na Tabela 5.4 são apresentados os dados relativos a quanto do tempo do usuário ele tinha pelo menos uma parte da área de interesse sendo observada.

Lembramos que um usuário pode ter ao mesmo tempo mais de uma área sendo foco de sua atenção e por isso a soma das porcentagens da Tabela 5.4 resultam em um valor superior a 100%.

Tabela 5.2: Listagem dos recursos por área da página do Facebook.

Área	Recursos
Chat	chat
Grupos, eventos e aplicativos	grupos eventos aplicativos páginas
Recomendados	grupos eventos páginas anúncios
Notificações	notificações home menu
Feed de notícias	fotos vídeo posts curtidas perfis textos comentários

Tabela 5.3: Porcentagem de clicks por área da página do Facebook.

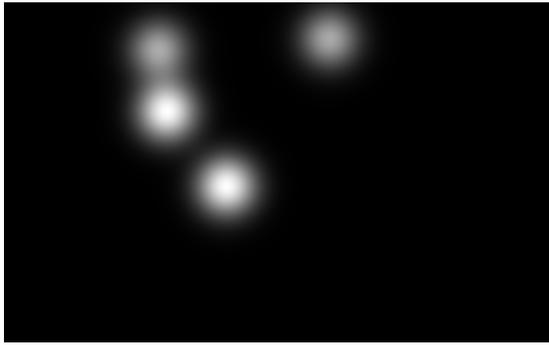
Área	Porcentagem de clicks da página do Facebook.
Feed de notícias	59,20%
Notificações	18,55%
Recomendados	10,20%
Grupos, eventos e aplicativos	10,20%
Chat	5,41%

Tabela 5.4: Porcentagem de visualizações por área da página do Facebook.

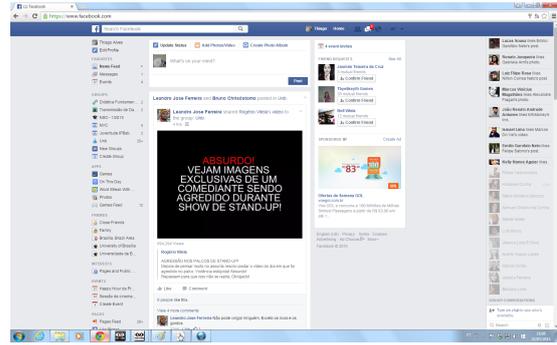
Área	Porcentagem de visualizações
Feed de notícias	94,22%
Grupos, eventos e aplicativos	73,50%
Recomendados	38,90%
Notificações	12,05%
Chat	8,14%

5.2.1 Capturas de tela, fixações e mapas de saliência

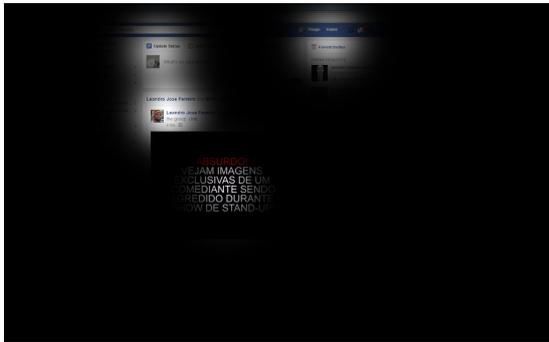
Foram coletadas, em média, 904 capturas de tela por usuário. Para cada captura, o eye-tracker retornou 10 fixações e, por meio de uma filtragem gaussiana dos pontos representando as posições das fixações, foram gerados os mapas de saliência. Obtivemos uma



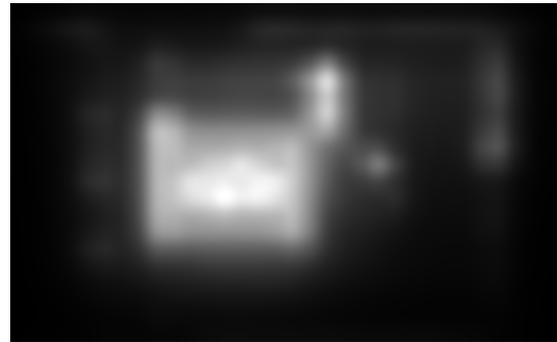
(a) mapa de saliência contendo as fixações do olhar de um participante.



(b) captura de tela da página do Facebook.



(c) mapa de saliência(a) sobreposto à captura de tela de(b).



(d) mapa de saliência obtido utilizando o GBVS.

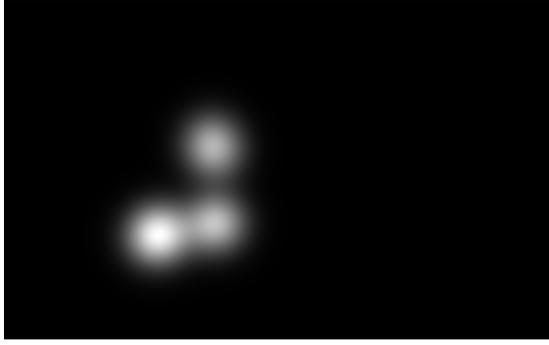
Figura 5.1: Dados Coletdos

sobreposição dos mapas com as capturas de tela, o que nos permite observar exatamente o foco de atenção visual dos usuários durante o experimento. Nas Figuras 5.1 e 5.2 são apresentados exemplos dos mapas de saliência subjetivos adquiridos no experimento. As figuras mostram também os mapas de saliência objetivos gerados pelo modelo de atenção visual GBVS a partir das capturas de tela.

5.2.2 Proporção entre áreas salientes e as áreas do Facebook

Neste trabalho, foram comparadas as áreas dos mapas de saliência de forma semelhante à análise feita por Giusti [18]. Mais especificamente, realizou-se uma medida da quantidade de pixels (área) do mapa de saliência que estão localizados em cada área da região de interesse. Foram calculadas a área total da imagem considerada saliente (A_S), a área de cada máscara de área de interesse (A_R), a área saliente em cada área de interesse (A_{RS}) e a área total das regiões de interesse (A_T). Com estes dados, calculamos, para cada mapa de saliência, as seguintes medidas:

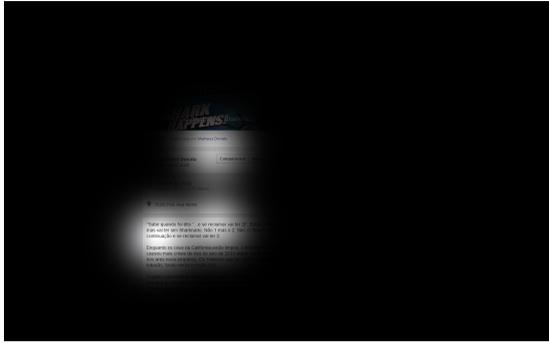
- Proporção da região de interesse saliente (P_{RS}): A razão entre a área da região



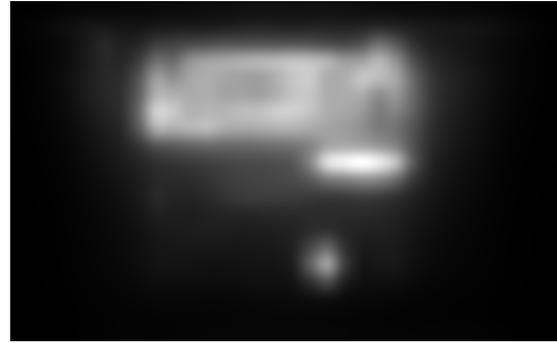
(a) mapa de saliência contendo as fixações do olhar de um participante.



(b) captura de tela da página do Facebook.



(c) mapa de saliência(a) sobreposto à captura de tela(b).



(d) mapa de saliência obtido utilizando o GBVS.

Figura 5.2: Dados Coletados

saliente da imagem em cada área de interesse e a área da região de interesse. Esta proporção nos permite analisar a porcentagem da região de interesse que é saliente.

$$P_{RS} = A_{RS}/A_R.$$

- Proporção da região (P_R): A razão entre a área da máscara da região de interesse e a área total da região de interesse. Esta proporção nos permite quantificar a área de interesse a em relação a área total das regiões de interesse.

$$P_R = A_R/A_T.$$

Para o cálculo da área das regiões das páginas do Facebook, foram utilizadas as máscaras binárias das regiões. Cada máscara tem a dimensão de 1680 x 1050 pixels e a sua área é calculada como a soma dos seus termos (pixels com valor “1” ou “0”), ou seja, utilizando a seguinte equação:

$$A_R = \sum_{i=0}^{1680} \sum_{j=0}^{1050} p_{i,j}.$$

no qual $p_{i,j}$ é o valor do pixel (i,j) da imagem. A área total da captura de tela é o somatório da área das máscaras das regiões de interesse, ou seja:

$$A_T = \sum_{i=0}^{1680} \sum_{j=0}^{1050} p_{i,j}.$$

Na Tabela 5.5 são apresentados os resultados obtidos utilizando as definições acima, onde apresentamos as médias das medidas para imagens.

Tabela 5.5: Resultado da análise de dados das proporções.

Área(em pixels)	P_{RS}	P_R
Feed de notícias	33.99	37.86
Grupos, eventos e aplicativos	21.14	14.82
Recomendados	6.42	20.83
Notificações	3.65	1.55
Chat	2.07	24.94

Observa-se que grande parte do layout do Facebook é composto pelo feed de notícias (ver Figura 4.3(b)). As regiões de chat, recomendados e grupos, eventos e aplicativos ocupam um espaço semelhante na tela. Mesmo com uma área muito extensa o feed foi considerado saliente. Entre todas as regiões de interesse, esta foi a que apresentou maior porcentagem de saliência (33%), o que confirma a sua importância. A região grupos, eventos e aplicativos, apesar de ter uma das menores áreas, foi bastante saliente. Possivelmente, isso acontece porque nesta região encontramos recursos que permitem a interação dos usuários, seja participando de um grupo, confirmando presença em um evento ou utilizando um aplicativo. Desta forma, os recursos desta região de interesse têm uma maior chance de serem reutilizados. A região do chat apresentou uma saliência muito baixa, principalmente quando levamos em conta sua grande dimensão.

5.3 Comparação entre clicks e áreas salientes

Como esperado, a área do *feed* de notícias predominou tanto como foco da atenção visual quanto dos clicks. Isso é compreensível por essa ser a principal área de divulgação de informação da rede, onde se concentra a maioria dos recursos, como por exemplo, *posts*, fotos, vídeos, perfis e comentários.

Por outro lado, houve discrepância na área das notificações, que aparece como uma das mais clicadas, mas pouco foi focada. Entretanto, esta discrepância parece razoável quando observamos a natureza deste recurso. A área de notificações mostra a chegada de uma nova notificação por meio de um sinal vermelho. Quando ele aparece, os usuários

clicam pra saber o motivo da notificação. Caso eles não possuam notificações, não há necessidade de olhar para essa área.

Em seguida temos a área de grupos, eventos e aplicativos, que corresponde a recursos de interesse do usuário – o que explica sua grande quantidade de clicks. Sua alta visibilidade, juntamente com a área de recomendados, acontece provavelmente devido à proximidade do *feed* de notícias. Apesar do seu posicionamento, a área de recomendados, que contém sugestões que vão desde amigos para adicionar, páginas para seguir, e até produtos para comprar, tem a menor quantidade de clicks. As sugestões dessa área são baseadas no perfil que a rede traça do usuário baseado nas suas atividades na rede. Todavia, no experimento, isto não parece atrair eficazmente o usuário, especialmente no que se refere aos anúncios de produtos, que não receberam nenhum click no experimento.

Os anúncios patrocinados podem também aparecer na área do *feed* de notícias, o que dá uma visibilidade aos anúncios. Ainda assim, nenhum anúncio foi alvo de click pelos participantes. Finalmente, há o recurso de *chat*, que foi muito pouco visualizado. Uma possível razão é a sua posição no canto inferior direito da tela, muito distante dos outros recursos. A área do chat também foi a que teve o menor número de clicks. O pouco uso deste recurso é compreensível quando sabe-se que existe um aplicativo para smartphones do Facebook que permite aos usuários conversarem. Além disso, é sabido que as redes sociais vem perdendo o mercado de troca de mensagens para aplicativos como WhatsApp [16].

Percebe-se que, pela quantidade pequena de clicks no decorrer do experimento, a navegação na rede ocorre com pouca utilização dos recursos disponibilizados pela plataforma. O foco das atividades estão no *feed* de notícias e nas interações com outros usuários que, quando não ocorrem pelo próprio *feed*, vão ser realizadas pelas notificações ou *chat*. A pouca utilização das recomendações dadas pelo Facebook, mesmo com a sua boa visibilidade, mostra que é necessária uma revisão destes recursos para torná-los mais eficazes.

5.3.1 Comparação dos mapas

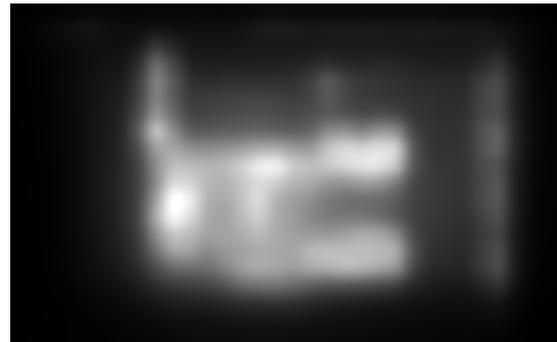
A Tabela 5.6 apresenta os resultados em termos de **AUC** [38] (Area Under Roc Curve) obtidos ao compararmos os mapas das fixações com os mapas gerados pelo GBVS. Calculamos o **AUC** entre os mapas subjetivos e objetivos correspondentes.

Verificou-se que os valores de **AUC** foram muito baixos, o que significa que a semelhança entre os mapas subjetivos e objetivos é baixa. Vale salientar que, valores de **AUC** inferiores a 0,5 correspondem a um desempenho de previsão pior que o obtido com mapas de saliência gerados aleatoriamente. Por outro lado, esse resultado é interessante uma vez que nos permite analisar os elementos que o modelo GBVS considerou como salientes e compará-los aos objetos da página que foram salientes para os observadores. Por exemplo,

na Figura 5.3 temos um caso de uma página do facebook que obteve um bom resultado, obtendo um valor de **AUC** igual a 0,831. Nesse caso, podemos ver que uma imagem toma boa parte da página do Facebook e, conseqüentemente, do campo visual do observador. De acordo com o *eye-tracker*, o usuário está fixando o olhar nesta imagem. O GBVS, por ser um algoritmo bottom-up que realiza uma análise da cor, intensidade e orientação das regiões da captura de tela, naturalmente fornece altos valores de saliência às imagens.



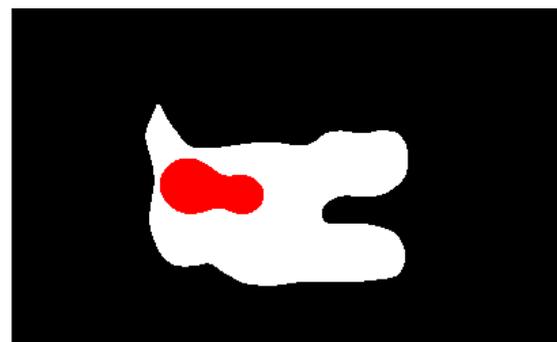
(a) captura da tela.



(b) mapa GBVS.



(c) mapa das fixações GBVS.



(d) análise AUC.

Figura 5.3: Exemplo de uma comparação de mapas subjetivos e objetivos que obteve um AUC de valor alto.

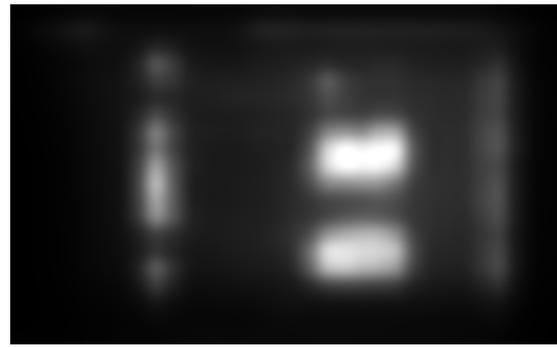
Um caso com um baixo valor de **AUC** (0,131) é apresentado na Figura 5.4. No exemplo, verifica-se que o usuário estava lendo um texto que continha as informações sobre um *post*. Apesar deste *post* estar centralizado na tela, o mapa gerado pelo GBVS não salienta textos e comentários. O que fica em destaque no mapa de saliência GBVS são as imagens dos

Tabela 5.6: Tabela de resultados AUC obtidos na comparação dos mapas de saliência experimentais e os mapas de saliência objetivos obtidos com o algoritmo GBVS.

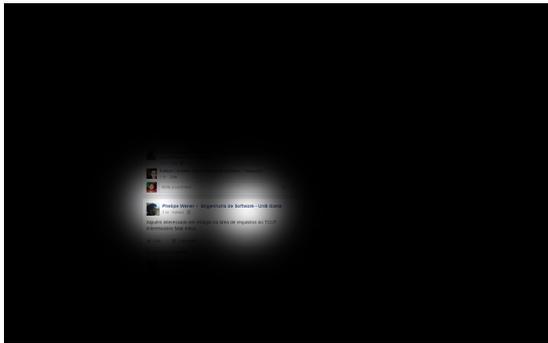
AUC	Valor
Média dos usuários	0,196
Maior valor de um usuário	0,273
Menor valor de um usuário	0,11



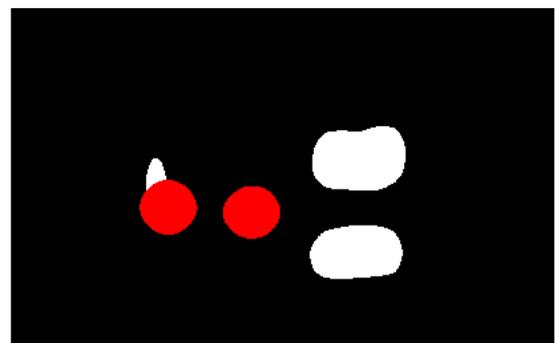
(a) captura da tela.



(b) mapa GBVS.



(c) mapa das fixações GBVS.



(d) análise AUC.

Figura 5.4: Exemplo de uma comparação de mapas subjetivos e objetivos que obteve um AUC de valor baixo.

perfis de outros usuários da rede e os anúncios de produtos na seção de recomendados. Dessa forma, nos casos em que os usuários estão lendo textos de posts e comentários, os mapas de saliência gerados pelo modelo GBVS se mostram bem diferentes dos mapas de saliência experimentais. Ou seja, o GBVS tem baixo desempenho de predição de áreas salientes quando os usuários estão realizando atividades específicas *top-down*. Ao contrário, quando o usuário está passivamente navegando na página, os mapas de saliência do GBVS são mais semelhantes aos mapas experimentais. Devido ao grande número de textos, descrições e comentários presentes nas páginas do Facebook, é compreensível o baixo desempenho dos mapas.

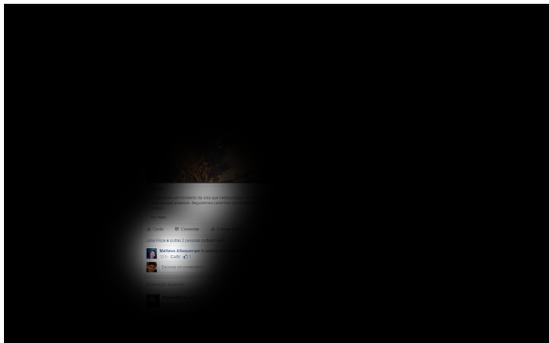
Desta forma, devido ao caráter de navegação ativa predominante no Facebook, o modelo de atenção visual bottom-up GBVS não se mostra eficaz para a análise do comportamento de um usuário na rede social. Embora o usuário observe imagens e posts para decidir a área de interesse, a navegação do usuário é, em grande parte do tempo, orientada às tarefas. Para uma melhor previsão das áreas salientes de uma página de rede social, seria mais indicado a utilização de um modelo de atenção visual top-down. O modelo apropriado deve ser capaz de identificar os textos e elementos salientes no próprio texto, como fontes de tamanhos, cores e estilos diferentes, palavras-chaves e *hyperlinks*,

dentre outros. Além disso, um modelo *top-down* pode ser capaz de identificar tarefas que são comuns na rede social e as notificações produzidas pelas diversas ações dos usuários.

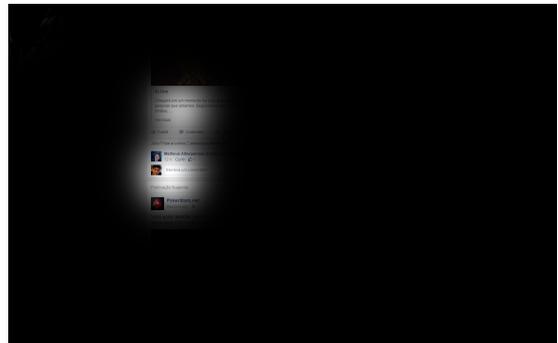
5.3.2 Fixações anteriores aos clicks

Também foram observadas as sequências de fixações dos usuários antes de realizarem um click. Esses mapas nos permitem ver o que o usuário fazia antes de clicar e as possíveis influências que ele recebeu. Na Figura 5.5. temos um exemplo das fixações antes de um click em uma foto que se encontrava no feed de notícias. Anteriormente ao click, o usuário vem lendo posts e comentários até que ele encontra um que chama sua atenção. O ato de navegar pelo feed em busca de posts interessantes foi o comportamento mais repetido pelos usuário o que explica a predominância dos feeds nos mapas de saliência. Um caso parecido com esse é apresentado na Figura 5.6. Entretanto, neste caso, o usuário não encontra algo de seu interesse no feed de notícias e nem em um anúncio que ele observa. Então, o usuário decide conversar com alguém no chat.

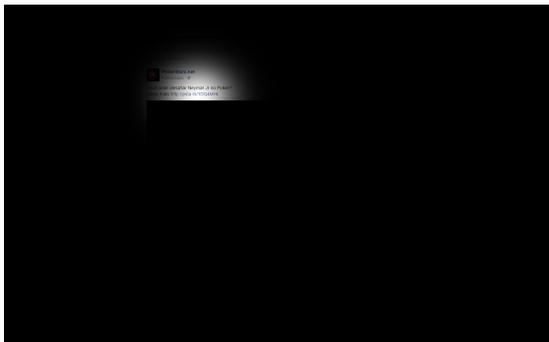
Na Figura 5.7 temos um exemplo de um usuário que logo que se conecta percebe que tem uma notificação. Porém, primeiro ele vê os anúncios, observa os usuários que estão no chat do facebook. Em seguida ele vê o primeiro post de seu feed e somente após isso vai ver suas notificações. Podemos perceber aqui a eficácia do aviso das notificações nas redes para um usuário recém conectado. Assim, concluímos as análises realizadas.



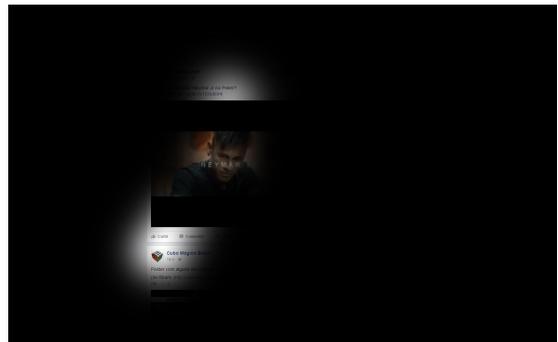
(a) Participante do experimento lê um texto e seu comentário..



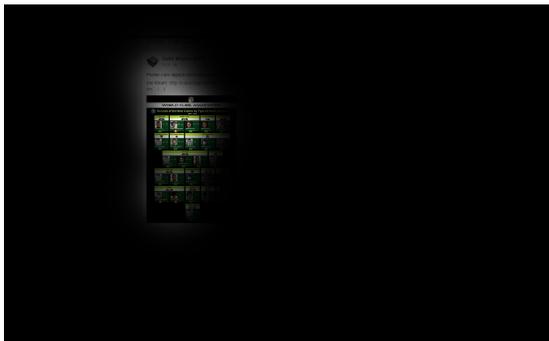
(b) Participante do experimento passa do comentário para o próximo post.



(c) Participante do experimento lê o texto do novo post.



(d) Participante do experimento vê a imagem do post e vê o autor do post seguinte.



(e) Participante do experimento se interessa pelo post e clica em sua imagem.

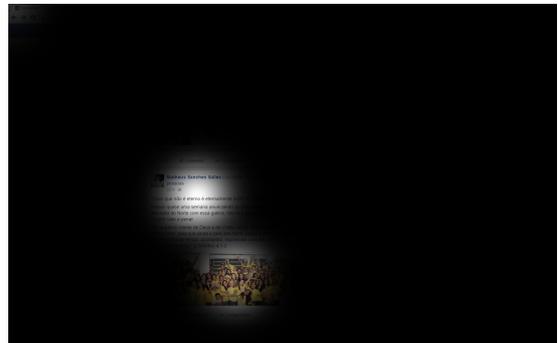


(f) Captura de tela com indicação da área do click.

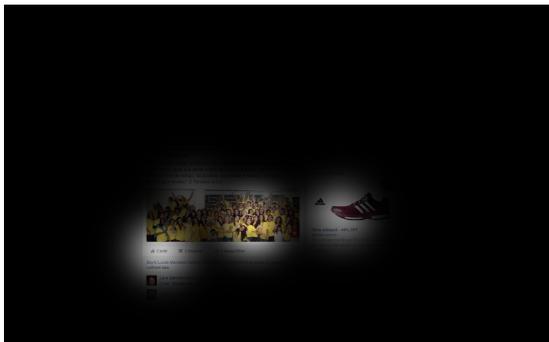
Figura 5.5: Fixações antes de click em uma foto no feed de notícias.



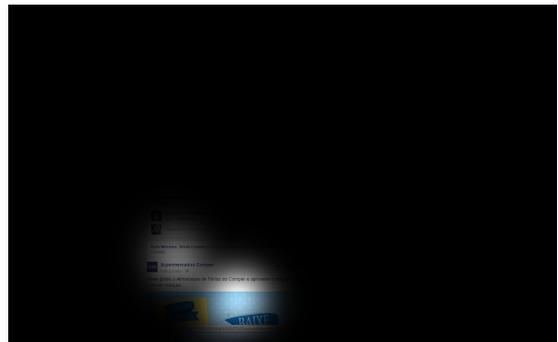
(a) Participante do experimento lê post.



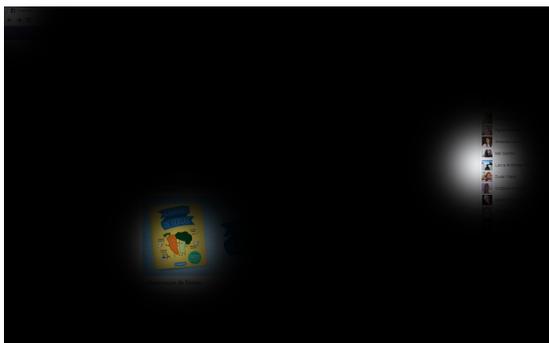
(b) Participante do experimento termina de ver o texto e observa a figura do post.



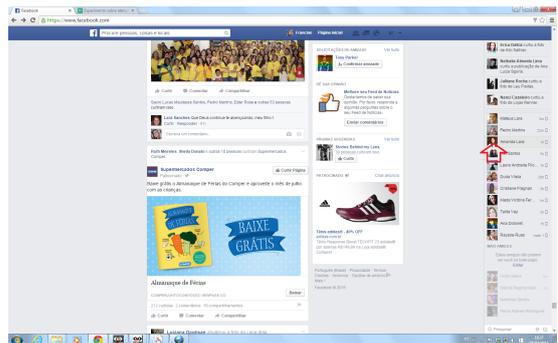
(c) Participante do vê a figura do post e a imagem de um anúncio.



(d) Participante do experimento observa a imagem do próximo post.

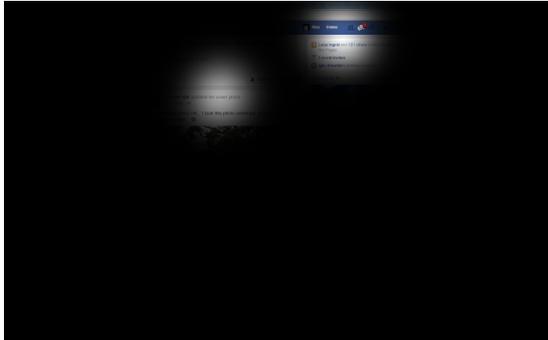


(e) Participante do experimento observa os usuários do Facebook no seu chat e clica em um deles.



(f) Captura de tela com indicação da área do click.

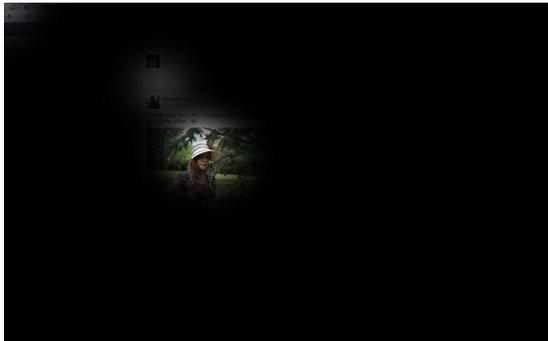
Figura 5.6: Fixações antes de click no chat.



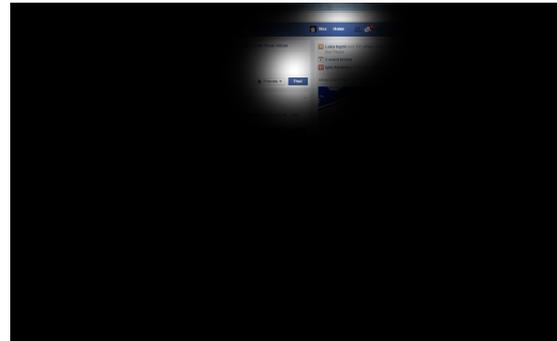
(a) Participante do experimento entra na rede e percebe que possui uma notificação.



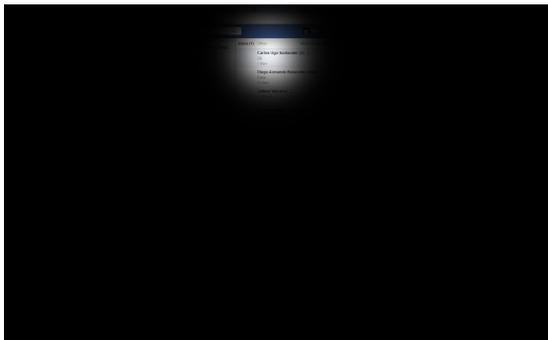
(b) Participante do experimento vê um anúncio e observa os usuários do Facebook em seu chat.



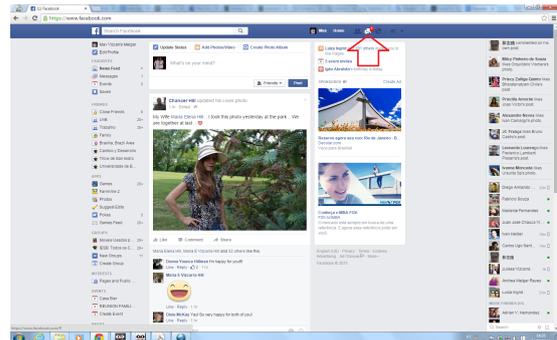
(c) Participante do experimento observa a imagem de seu primeiro post.



(d) Participante do experimento olha algumas recomendações antes de se voltar para a sua notificação.



(e) Participante do experimento clica na sua notificação.



(f) Captura de tela com indicação da área do click.

Figura 5.7: Fixações antes de click na notificação.

Capítulo 6

Conclusão

Neste trabalho, foi estudado o comportamento de usuários da rede social Facebook. Utilizando um *Eye-tracker* estudamos o caminho que o olhar de um usuário percorre ao visitar a página do Facebook; analisou-se as áreas da página e os recursos que mais lhe atraíram a atenção; e, estudou-se a sua utilização da rede social por meio da análise da distribuição e da quantidade dos clicks realizados. Foi observado que as atividades dos usuários se concentram na área do *feed* de notícias, devido ao grande número de clicks e o grande foco de atenção recebido por esta área. Vale salientar que nesta área o usuário pode adquirir informações e interagir com os outros usuários, o que a torna naturalmente atrativa. Exceções corresponderam a atividades específicas e pontuais, como consulta a grupos e eventos e as notificações vindas dos outros usuários.

Foi identificada uma utilização pequena da área de sugestões do Facebook, onde ficam indicações de amigos, sugestões de eventos e anúncios de produtos. Isso ocorre apesar da área ter recebido grande atenção visual dos usuários, o que pode significar que esta área não possui conteúdo semântico interessante.

A utilização do Facebook pelos usuários se mostrou semelhante à utilização de outras redes sociais que permitem apenas o uso do *feed* de notícias, como o Instagram – que tem o foco em imagens – e o Twitter – que tem o foco em mensagens. Vale salientar que o Facebook já permite a utilização do *feed de notícias* para anúncios. Entretanto, o nosso estudo mostrou que os anúncios do *feed* apresentam uma baixa atratividade, com nenhum dos participantes clicando nos anúncios.

Outro enfoque foi o estudo da viabilidade do uso de um modelo de atenção visual para a análise das redes sociais. O modelo GBVS se mostrou ineficaz, neste contexto. Isso correu possivelmente em virtude deste ser um modelo *bottom-up* e, por isso, analisar apenas as características intrínsecas da página e não ressaltar textos e tarefas. Um trabalho futuro interessante seria a comparação das fixações com os mapas de saliência gerados por um modelo *top-down* projetado para identificar tarefas e regiões de alta saliência em páginas

de redes sociais.

Fica evidente, neste estudo, que a análise do comportamento de usuários em redes sociais é viável. Em especial, dado o fácil acesso a eye-trackers não intrusivos e sistemas computacionais que permitem a captação de dados clickstream, é possível realizar estudos elaborados do comportamento de usuários em redes sociais, analisando que tipo de ferramenta e/ou recurso tem a maior taxa de sucesso em atrair a atenção do usuário.

Referências

- [1] https://en.wikipedia.org/wiki/Human_eye#/media/File:Schematic_diagram_of_the_human_eye_en.svg, 2015. [Online; acessado 15-Janeiro-2016]. 9
- [2] Welington Yorihiko Lima Akamine. Utilizando modelos bottom-up de atenção visual para análise de qualidade visual. 2014. 12
- [3] Ana Isabel Albuquerque and Ana Serrano Tellería. Instagram e celebridades: a utilização da fotografia nas redes sociais. *Comunicação Pública*, 9(n15), 2014. 6
- [4] Ana Margarida Barreto. Eye tracking como método de investigação aplicado às ciências da comunicação. *Revista Comunicando*, 1(1):168–186, 2012. 15
- [5] Fabrício Benevenuto, Tiago Rodrigues, Meeyoung Cha, and Virgílio Almeida. Characterizing user behavior in online social networks. In *Proceedings of the 9th ACM SIGCOMM conference on Internet measurement conference*, pages 49–62. ACM, 2009. 2
- [6] Danah M Boyd. Friendster and publicly articulated social networking. 2004. 6
- [7] Inês Maria Pereira Branquinho. O impacto do facebook na publicidade online: uma perspectiva google versus facebook. 2014. 8
- [8] Moira Burke, Robert Kraut, and Cameron Marlow. Social capital on facebook: Differentiating uses and users. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 571–580. ACM, 2011. 7
- [9] Moira Burke, Cameron Marlow, and Thomas Lento. Feed me: motivating newcomer contribution in social network sites. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 945–954. ACM, 2009. 2
- [10] Charles E Connor, Howard E Egeth, and Steven Yantis. Visual attention: bottom-up versus top-down. *Current Biology*, 14(19):R850–R852, 2004. 12
- [11] Raquel da Cunha Recuero. Teoria das redes e redes sociais na internet: considerações sobre o orkut, os weblogs e os fotologs. In *XXVII Congresso Brasileiro de Ciências da Comunicaç ao. XXVII INTERCOM*, 2004. 5
- [12] Nicole B Ellison et al. Social network sites: Definition, history, and scholarship. *Journal of Computer-Mediated Communication*, 13(1):210–230, 2007. 6

- [13] Pedro F Felzenszwalb, Ross B Girshick, David McAllester, and Deva Ramanan. Object detection with discriminatively trained part-based models. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 32(9):1627–1645, 2010. 14
- [14] Daniele Ferreira and Welington Akamine. Um estudo sobre o impacto da atenção visual nas redes sociais. 2012. 2
- [15] Jacques de Lima Ferreira, Barbara Raquel do Prado Gimenez Corrêa, and Patrícia Lupion Torres. O uso pedagógico da rede social facebook. *Colabor@-A Revista Digital da CVA-RICESU*, 7(28), 2013. 7
- [16] NAIARA SILVA FERREIRA and EMILIO JOSÉ MONTERO ARRUDA FILHO. Preferência de uso das redes sociais virtuais para o consumidor tecnológico: Uma análise do facebook versus whatsapp. 2014. 29
- [17] Alessandro Foi and Giacomo Boracchi. Foveated self-similarity in nonlocal image filtering. In *IS&T/SPIE Electronic Imaging*, pages 829110–829110. International Society for Optics and Photonics, 2012. vi, 11
- [18] Paulo Ricardo Xavier Giusti. Estudo sobre o comportamento de usuários em redes sociais sob um modelo computacional de atenção visual. 2015. 26
- [19] Minas Gjoka, Michael Sirivianos, Athina Markopoulou, and Xiaowei Yang. Poking facebook: characterization of osn applications. In *Proceedings of the first workshop on Online social networks*, pages 31–36. ACM, 2008. 2
- [20] Nils Gustafsson. The subtle nature of facebook politics: Swedish social network site users and political participation. *New Media & Society*, 14(7):1111–1127, 2012. 7
- [21] Jonathan Harel, Christof Koch, and Pietro Perona. Graph-based visual saliency. In *Advances in neural information processing systems*, pages 545–552, 2006. 1, 10, 12, 20
- [22] Julia Heidemann, Mathias Klier, and Florian Probst. Online social networks: A survey of a global phenomenon. *Computer Networks*, 56(18):3866–3878, 2012. 5
- [23] John M Henderson. Visual attention and eye movement control during reading and picture viewing. In *Eye movements and visual cognition*, pages 260–283. Springer, 1992. 10
- [24] Aapo Hyvärinen, Jarmo Hurri, and Patrick O Hoyer. *Natural Image Statistics: A Probabilistic Approach to Early Computational Vision.*, volume 39. Springer Science & Business Media, 2009. 9
- [25] Laurent Itti and Christof Koch. Computational modelling of visual attention. *Nature reviews neuroscience*, 2(3):194–203, 2001. 9, 14
- [26] Laurent Itti, Christof Koch, and Ernst Niebur. A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (11):1254–1259, 1998. vi, 1, 10, 12, 13

- [27] RJ Jacob and Keith S Karn. Eye tracking in human-computer interaction and usability research: Ready to deliver the promises. *Mind*, 2(3):4, 2003. 15
- [28] Robert JK Jacob. Eye tracking in advanced interface design. *Virtual environments and advanced interface design*, pages 258–288, 1995. 15
- [29] Tilke Judd, Frédo Durand, and Antonio Torralba. A benchmark of computational models of saliency to predict human fixations. 2012. 12
- [30] Tilke Judd, Krista Ehinger, Frédo Durand, and Antonio Torralba. Learning to predict where humans look. In *Computer Vision, 2009 IEEE 12th international conference on*, pages 2106–2113. IEEE, 2009. 1, 10, 12, 13
- [31] Gwangjae Jung and Byungtae Lee. How did facebook outpace myspace with open innovation? an analysis of network competition with changes of network topology. In *PACIS*, page 88. Citeseer, 2011. 7
- [32] Michael L Kasavana, Khaldoon Nusair, and Katherine Teodosic. Online social networking: redefining the human web. *Journal of Hospitality and Tourism Technology*, 1(1):68–82, 2010. 7
- [33] Daejoong Kim, Jang-Hyun Kim, and Yoonjae Nam. How does industry use social networking sites? an analysis of corporate dialogic uses of facebook, twitter, youtube, and linkedin by industry type. *Quality & Quantity*, 48(5):2605–2614, 2014. 7
- [34] Balachander Krishnamurthy. A measure of online social networks. In *Communication Systems and Networks and Workshops, 2009. COMSNETS 2009. First International*, pages 1–10. IEEE, 2009. 2
- [35] Olivier Le Meur, Patrick Le Callet, Dominique Barba, and Dominique Thoreau. A coherent computational approach to model bottom-up visual attention. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 28(5):802–817, 2006. 12
- [36] Jure Leskovec, Lada A Adamic, and Bernardo A Huberman. The dynamics of viral marketing. *ACM Transactions on the Web (TWEB)*, 1(1):5, 2007. 2
- [37] Marcel Magalhães. <https://github.com/marcelmagalhaes/0-Papel-da-Aten--o-Visual-nas-Redes-Sociais>, 2015. [Online; acessado 29-Dezembro-2015]. 19
- [38] Marcel Magalhães. https://github.com/cvzoya/saliency/tree/master/code_forMetrics, 2015. [Online; acessado 29-Dezembro-2015]. 29
- [39] Stanley Milgram. The small world problem. *Psychology today*, 2(1):60–67, 1967. 5, 6
- [40] Eva Mohedano. <http://bitsearch.blogspot.com.br/2013/05/saliency-maps-and-their-computation.html>, 2013. [Online; acessado 28-Dezembro-2015]. vi, 14
- [41] Amy L Parsons. Social media from a corporate perspective: A content analysis of official facebook pages. In *Proceedings of the academy of marketing studies*, volume 16, pages 11–15, 2011. 8

- [42] Rodrigo Cerqueira Gonzalez Pena. Métricas de qualidade de vídeo com características top-down de atenção visual. 2014. 14
- [43] Mariana Vassallo Piza. O fenômeno instagram: considerações sob a perspectiva tecnológica. 2012. 6
- [44] Alzimar Ramalho and Francisco Barroso. Fakes no twitter: um estudo sobre um fake político no distrito federal. *Comunicologia-Revista de Comunicação e Epistemologia da Universidade Católica de Brasília*, 7(2):03–26, 2015. 6
- [45] Raquel da Cunha Recuero. Um estudo do capital social gerado a partir de redes sociais no orkut e nos weblogs. *Revista FAMECOS: mídia, cultura e tecnologia*, 1(28), 2006. 6
- [46] Daniel C Richardson and Michael J Spivey. Eye tracking: Characteristics and methods. *Encyclopedia of biomaterials and biomedical engineering*, 3:1028–1042, 2004. 15
- [47] Katherine K Roberts. Privacy and perceptions: How facebook advertising affects its users. *The Elon Journal of Undergraduate Research in Communications*, 1(1):24–34, 2010. 6, 8
- [48] Joaquim Carlos Rossini and César Galera. Atenção visual: estudos comportamentais da seleção baseada no espaço e no objeto. *Estudos de Psicologia*, 11(1):79–86, 2006. 10
- [49] Bryan C Russell, Antonio Torralba, Kevin P Murphy, and William T Freeman. Labelme: a database and web-based tool for image annotation. *International journal of computer vision*, 77(1-3):157–173, 2008. 14
- [50] Tracii Ryan and Sophia Xenos. Who uses facebook? an investigation into the relationship between the big five, shyness, narcissism, loneliness, and facebook usage. *Computers in Human Behavior*, 27(5):1658–1664, 2011. 7
- [51] John T Serences and Steven Yantis. Selective visual attention and perceptual coherence. *Trends in cognitive sciences*, 10(1):38–45, 2006. 10
- [52] Christine A Skarda and Walter J Freeman. How brains make chaos in order to make sense of the world. *Behavioral and brain sciences*, 10(02):161–173, 1987. 9
- [53] Antonio Torralba, Aude Oliva, Monica S Castelhana, and John M Henderson. Contextual guidance of eye movements and attention in real-world scenes: the role of global features in object search. *Psychological review*, 113(4):766, 2006. 14
- [54] The Eye Tribe. <https://theeyetribe.com/products/>, 2015. [Online; acessado 5-Dezembro-2015]. vi, vii, 17, 18, 20
- [55] Paul Viola and Michael J Jones. Robust real-time face detection. *International journal of computer vision*, 57(2):137–154, 2004. 14

- [56] Bimal Viswanath, Alan Mislove, Meeyoung Cha, and Krishna P Gummadi. On the evolution of user interaction in facebook. In *Proceedings of the 2nd ACM workshop on Online social networks*, pages 37–42. ACM, 2009. 2
- [57] Dirk Walther. *Interactions of visual attention and object recognition: computational modeling, algorithms, and psychophysics*. PhD thesis, Citeseer, 2006. 13
- [58] Shanyang Zhao, Sherri Grasmuck, and Jason Martin. Identity construction on facebook: Digital empowerment in anchored relationships. *Computers in human behavior*, 24(5):1816–1836, 2008. 6