

UNIVERSIDADE FEDERAL DO PARANÁ

RENAN LUCIANO BURDA

DEFININDO O *LAYOUT* DE UM *E-COMMERCE* PELA INTERAÇÃO DO
USUÁRIO BASEADO EM APRENDIZADO DE MÁQUINA

CURITIBA PR
JANEIRO DE 2017

RENAN LUCIANO BURDA

DEFININDO O *LAYOUT* DE UM *E-COMMERCE* PELA INTERAÇÃO DO
USUÁRIO BASEADO EM APRENDIZADO DE MÁQUINA

Trabalho apresentado como requisito parcial à conclusão do Curso de Bacharelado em Ciência da Computação, setor de Ciências Exatas, da Universidade Federal do Paraná.

Área de concentração: *Ciência da Computação*.

Orientador: Dr. David Menotti.

CURITIBA PR
JANEIRO DE 2017

Agradecimentos

Agradeço a todos que contribuíram de alguma forma no desenvolvimento deste trabalho. Em especial gostaria de citar três pessoas: David Menotti, meu orientador, Tamires Marcela Burda, minha irmã e Fabricio José de Oliveira Ceschin, grande amigo que esteve presente em todo o decorrer do curso.

Resumo

É incontável o número de usuários que fazem uso de *websites*, nos quais informações de interação com a interface, que podem ser relevantes para melhorá-la, além de não serem aproveitadas, são descartadas. Neste sentido, neste trabalho, é proposto uma abordagem baseada em aprendizado de máquina para o uso de informações com a interface de cada usuário para direcioná-lo a um *layout* específico (i.e., textual ou visual) de forma a aumentar seu tempo de sessão – desejável em *E-commerces*. Deste modo, foi desenvolvido um estudo de caso em um portal de veículos, funcional desde 2013, do próprio autor deste trabalho [Burda, 2013]. O resultado é uma confirmação estatística da proposta deste trabalho, no qual uma mudança de layout pode melhorar a interação do usuário com o sistema e, conseqüentemente, um tempo de sessão maior é atingido.

Palavras-chave: Interação com Interface, Aprendizado de máquina, Comportamento do usuário, Visual vs Textual.

Abstract

It is impossible to count the number of users who use a website where interface interaction informations, which can be relevant to improve it, are not used and are discarded. In this work, we propose a machine learning based approach that uses interface interaction informations of each user, to direct him/her to a specif layout (textual or visual) in order to increase his/her session time – desirable in e-commerces. A case study was developed in a vehicles e-commerce, which is online since 2013 and was created by the same author of this work [Burda, 2013]. As a result of our experimentation, we obtain a statistic confirmation of the proposal, where the layout changes can improve the users interaction with the system and, consequently, increase the overall session time.

Sumário

1	Introdução	1
1.1	Organização do documento	1
2	Fundamentos	5
2.1	Fundamentos Teóricos	5
2.1.1	Aprendizado de Máquina	5
2.1.2	Normalização	7
2.1.3	<i>Layout</i>	7
2.1.4	Usuário	8
2.2	Fundamentos Tecnológicos	8
2.2.1	Python	8
2.2.2	Cookies	8
2.2.3	Javascript	8
2.2.4	Json	9
2.2.5	<i>Flask</i>	9
2.2.6	<i>Scikit Learn</i>	9
2.2.7	Web Services	9
2.2.8	REST	9
2.2.9	Md5	9
3	Revisão Bibliográfica	10
4	Proposta	12
4.1	Análise do comportamento	13
4.2	Coleta dos dados	13
4.2.1	Identificação única	14
4.3	Extração de características	14
4.3.1	Características	14
4.3.2	Eliminação de ruído	15
4.3.3	Normalização	15
4.3.4	Base inicial	15
4.4	Classificação de novos usuários	15
4.5	Alteração do layout	15
4.5.1	Genérico	15
4.5.2	Visual	16
4.5.3	Textual	17
4.6	<i>FeedBack</i>	18
4.7	Aprendizado <i>Online</i>	19

5	Validação	20
5.1	Experimentação	20
5.2	Resultados	20
5.2.1	Primeira fase	21
5.2.2	Segunda fase	24
5.3	Análise	26
5.3.1	Teste de Hipótese para a primeira fase	27
5.3.2	Teste de Hipótese para a segunda fase	27
5.3.3	Dificuldades	27
5.4	Discussão	28
6	Conclusão	29
6.1	Trabalhos Futuros	29
	Referências Bibliográficas	30

Lista de Figuras

1.1	Apresentação de anúncio padrão do portal Carro Quente [Burda, 2013]	2
1.2	Apresentação de anúncio <i>visual</i> do portal Carro Quente [Burda, 2013]	3
1.3	Apresentação de anúncio <i>textual</i> do portal Carro Quente [Burda, 2013]	4
2.1	Fronteira definida pelo SVM. Figura retirada de [scikit learn, 2012]	7
2.2	Exemplo de md5.	9
4.1	Diagrama geral da classificação.	13
4.2	Diagrama do ciclo de coleta dos dados.	14
4.3	Uma representação de layout genérico, no qual elementos vermelhos são do tipo V e azuis do tipo T.	16
4.4	Modelo de layout visual, no qual elementos vermelhos são do tipo V e azuis do tipo T.	17
4.5	Modelo de layout textual, no qual elementos vermelhos são do tipo V e azuis do tipo T.	18
4.6	Modelo de feedback.	18
5.1	Gráfico de dispersão entre o primeiro e segundo acesso sem classificação.	21
5.2	Gráfico de dispersão entre o primeiro e segundo acesso com <i>feedback</i>	24

Lista de Tabelas

4.1	Tabela de características.	14
5.1	Valores da primeira fase em minutos referentes ao primeiro acesso.	22
5.2	Informações sobre a amostra da Tabela 5.1	22
5.3	Valores da primeira fase em minutos referentes ao segundo acesso.	23
5.4	Informações sobre a amostra da Tabela 5.3	23
5.5	Valores da segunda fase em minutos referentes ao primeiro acesso.	25
5.6	Informações sobre a amostra da tabela 5.5	25
5.7	Valores da segunda fase em minutos referentes ao segundo acesso.	26
5.8	Informações sobre a amostra da tabela 5.7	26

Lista de Acrônimos

DINF	Departamento de Informática
PPGINF	Programa de Pós-Graduação em Informática
UFPR	Universidade Federal do Paraná

Capítulo 1

Introdução

A internet como conhecemos hoje apresenta uma diversidade de informações e usuários graças à sua expansão de maneira mundial [ITU, 2016, Brasil, 2016]. A interação do usuário com as páginas da *World Wide Web* (*www*) constitui um rico “ecossistema” de informações que poderia ser utilizado e estudado para aproveitar a experiência do usuário, entretanto, isso não é feito frequentemente.

Grandes lojas virtuais (*E-commerces*) foram criadas visando os mais diversos públicos. Para tentar agradar a todos, os produtos são apresentados de maneira padronizada e com características genéricas, não sendo levado em consideração o potencial de informações dos próprios clientes acerca do seu comportamento durante a navegação no portal. Assim, a utilização dos dados dessas interações pode ser uma ferramenta capaz de melhorar a “estadia” de cada usuário. O direcionamento dessas informações podem ser responsáveis por um eventual aumento no tempo de permanência dos usuários nos *e-commerces*, visto que podem ser utilizados para personalizar a apresentação dos produtos, buscas, entre outros itens. Para exemplificar, a Figura 1.1 apresenta um anúncio padrão do portal de veículos *Carro Quente* [Burda, 2013].

Visto isto, este trabalho tem como objetivo prever, usando aprendizado de máquina e a interação do usuário com a interface do *e-commerce*, uma melhor apresentação do portal visando aumentar o tempo de permanência do usuário. São propostas duas formas alternativas de apresentação: visual (Figura 1.2) e textual (Figura 1.3). Cada uma das apresentações citadas anteriormente apresenta uma modificação em comparação com a genérica (Figura 1.1), na qual os elementos determinados como visuais ou textuais terão a sua dimensão aumentada para seus respectivos *layouts*.

A coleta das informações de comportamento e preferência dos usuários para aprendizado de máquina [Bishop, 2007] será feita simplesmente pela maneira que o usuário utiliza o sistema, tempo de interações do *mouse* com botões e regiões de interesse, etc. Utilizando as informações coletadas, os usuários serão classificados entre as duas classes definidas anteriormente (“Textual” e “Visual”) e a modificação dos anúncios será realizada de acordo com a rotulação do usuário.

Este trabalho contribui apresentando uma proposta sobre a alteração da aparência de um portal baseado na interação dos usuários com os elementos do sistema, tendo como consequência a criação de uma base de dados que pode ser utilizada como ponto de partida para a análise deste tipo de proposta.

1.1 Organização do documento

Para melhor compreensão deste trabalho, ele foi dividido em capítulos. No Capítulo 2, as definições dos conceitos utilizados ao longo do estudo são apresentadas. O Capítulo 3

Capítulo 2

Fundamentos

Este capítulo apresenta os conceitos teóricos e tecnológicos que serão utilizados no desenvolvimento deste trabalho. A disposição dos fundamentos está agrupada em dois grandes grupos: Teóricos e Tecnológicos.

2.1 Fundamentos Teóricos

Nesta seção, os conceitos fundamentais para a compreensão do trabalho serão abordados e brevemente explicados.

2.1.1 Aprendizado de Máquina

Aprendizado de máquina é um sub-conjunto que evoluiu dos estudos em reconhecimento de padrões e da teoria de aprendizagem computacional em inteligência artificial. Desta forma refere-se a um grande conjunto de técnicas que visam especificar algoritmos capazes de aprender um determinado comportamento ou padrão de maneira automática a partir de exemplos ou simples observação [Wikipedia, 2017a, Zadrozny, 2010].

De maneira genérica, os algoritmos aprendem um modelo sobre os dados de treinamento para que seja possível prever o comportamento dos dados quando necessário. Os algoritmos são utilizados nos mais diversos campos, desde a previsão do comportamento de clientes a partir de dados de compras a previsão do tempo.

Características

Características é um termo utilizado em aprendizado de máquina para definir as propriedades de um indivíduo, ou seja, os atributos que definem a sua existência. Boas características devem ser invariantes e discriminantes.

Aprendizagem supervisionada

A aprendizagem supervisionada consiste em utilizar conhecimento previamente obtido, de modo a ser representado por um conjunto de dados etiquetados, ou seja, os dados já estão com suas respectivas saídas. Em um problema de classificação, a saída representa a classe respectiva ao dado consumido pelo classificador [Osório, 1999, Wikipedia, 2017a].

Classificador Supervisionado

Classificador supervisionado é um algoritmo que tem como funcionalidade determinar se um indivíduo pertence a uma determinada classe. Funciona em dois estágios: treinamento e predição. Na fase de treinamento, é apresentado ao classificador um conjunto de dados previamente classificados, e o mesmo cria um “conhecimento” sobre estes dados, a maneira como isto é feito depende do algoritmo empregado. A predição consiste em apresentar um conjunto de dados desconhecidos (classes não são conhecidas), desta forma, os dados são classificados baseados no conhecimento adquirido na fase de treinamento.

Aprendizado *on-line*

Em aprendizado de máquina, aprendizado online é um método baseado em avaliação dos resultados obtidos a partir de uma classificação, usando os dados obtidos para incrementar o modelo do classificador, ou seja, utilizar os dados para aprimorar o conhecimento do algoritmo. A prática é baseada em refinar a predição futura e tratar mudanças no comportamento dos dados [Wikipedia, 2017b].

FeedBack

O *feedback* pode ser definido como o processo no qual parte da saída do sistema é disponibilizada na entrada, tendo como intuito melhorar e avaliar os resultados obtidos [Wikipedia, 2016]. Neste trabalho existem três tipos de retorno para o *feedback*: Positivo, Negativo e Neutro. Positivo é quando o usuário está satisfeito, o negativo é quando o usuário não está satisfeito e o neutro é quando o *feedback* não é respondido pelo usuário.

Support Vector Machines (SVM)

O *Support Vector Machines (SVM)* é um classificador supervisionado que pode assumir diversas formas para definir a fronteira de decisão, na qual uma das possíveis é uma fronteira linear, ou seja, neste caso tem como fundamento a busca por padrões linearmente separáveis, tendo como principal característica a construção de um hiperplano como superfície de decisão (fronteira), de tal modo que a separação entre os exemplos seja máxima.

Quando os dados não são linearmente separáveis o algoritmo projeta estes dados em um plano de maior discriminação com o objetivo de serem linearmente separáveis, os parâmetros de transformação devem ser encontrada pelo algoritmo. A fronteira ideal é garantida pelo algoritmo. A Figura 2.1 ilustra a fronteira encontrada pelo SVM [Scikit-learn, 2012].

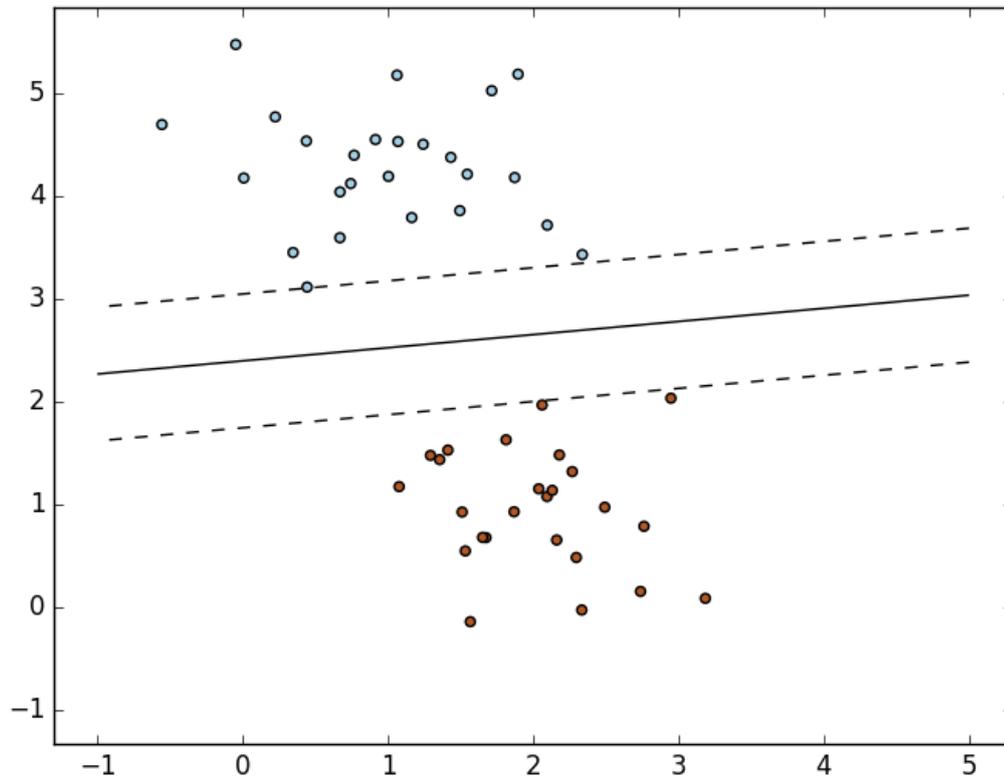


Figura 2.1: Fronteira definida pelo SVM. Figura retirada de [scikit learn, 2012]

2.1.2 Normalização

A normalização é, de forma geral, uma técnica utilizada para normalizar os dados que serão utilizados, ou seja, é basicamente uma forma de refinar os dados obtidos. Existem três técnicas que são mais comuns para esta tarefa, estas são: Min-Max, Pontuação Z e Dimensionamento decimal.

Como a Min-Max é uma das mais utilizadas 2.1.2 uma explicação mais detalhada será fornecida.

Min-Max

A normalização utilizando Min-Max transforma os dados de forma linear em um intervalo, no qual o intervalo vai estar entre o valor mínimo e o máximo. A Fórmula 2.1.2 representa esta operação.

$$f = (x - \min[k]) / (\max[k] - \min[k]) \quad (2.1)$$

2.1.3 Layout

O *layout* é definido como a forma que os elementos estão dispostos na página, desde tamanho até a cor dos objetos presentes.

2.1.4 Usuário

O conceito de usuário pode ser definido como pessoas que utilizam um determinado tipo de serviço. Neste trabalho, o conceito será empregado da forma geral, ou seja, toda e qualquer pessoa que acesse o sistema será considerada um usuário.

2.2 Fundamentos Tecnológicos

Nesta seção, estão definidas as tecnologias utilizadas no desenvolver deste trabalho para que exista uma melhor compreensão de como foi criada a proposta e experimentação.

2.2.1 Python

Python [Rossum, 1999] é uma linguagem de programação de alto nível, orientada a objetos e interpretada. A linguagem tem como princípio poupar o tempo do programador, tendo um curto tempo de desenvolvimento. Entretanto, os recursos computacionais envolvidos para executar a aplicação são altos. Essa linguagem destaca a legibilidade do código, fazendo com que por exemplo, a indentação seja artigo obrigatório. Além disso, permite que em poucas linhas de código seja feita a solução de problemas complexos, quando comparada a outras linguagens. O Python é utilizado amplamente no meio acadêmico devido sua alta curva de aprendizagem, sendo normalmente empregada em processamento de textos, dados científicos, aprendizado de máquina, entre outras.

2.2.2 Cookies

Cookie é um pequeno pacote de dados criado por um *website* e armazenado localmente no computador dos seus usuários. Os *cookies* são utilizados para armazenar informações relevantes e específicas do usuário para tal *website*. O acesso aos dados armazenados são disponíveis apenas quando o usuário acessa o *website* que criou o *cookie*, ou seja, o acesso é restrito a aplicação que criou o *cookie*.

2.2.3 Javascript

Javascript [Eich, 1995] é uma linguagem de programação de alto nível, interpretada e orientada a eventos. Foi implementada com o princípio de ser interpretada pelos navegadores web para que *scripts* fossem executados localmente, ou seja, diretamente no computador do usuário.

Como é orientado a eventos, é possível realizar comunicação assíncrona, por esta razão, essa linguagem é utilizada nas mais diversas tarefas, como por exemplo, na alteração de conteúdo a partir de um evento ou, até mesmo na requisição de informações para o servidor de uma aplicação web.

jQuery

jQuery [Resing, 2006] é uma biblioteca rápida e compacta implementada em *javascript*. Ela tem como objetivo ser *cross-browser*, pois como javascript é interpretada pelo navegador web, a portabilidade entre diferentes navegadores é problemática. Desta forma, bibliotecas como *jQuery* foram criadas a fim de resolver o problema de portabilidade.

2.2.4 Json

Json [Crockford, 2006] é um padrão para armazenar informações reconhecido pela sua simplicidade e facilidade na troca de informações entre aplicações. Tendo como principal característica a fácil interpretação por humanos ou máquinas. A interpretação do Json independe da linguagem de programação, pois é feita em um arquivo de texto aberto, tendo sua sintaxe baseada na linguagem *JavaScript*. Devido as suas características, é utilizado amplamente em aplicações que necessitam trocar informações.

2.2.5 Flask

O *Flask* [Ronacher, 2010] é uma biblioteca implementada em *Python* com o objetivo de facilitar a criação de micro aplicações Web, oferecendo suporte para a criação de *Web Services* em REST.

2.2.6 Scikit Learn

A *Scikit Learn* é uma biblioteca de aprendizado de máquina *open source* implementada em python, sendo composta de diversos algoritmos de classificação, regressão e agrupamento, implementados utilizando outras bibliotecas numéricas e científicas (Numpy e SciPy) [Pedregosa et al., 2011].

2.2.7 Web Services

O *Web Services* é uma solução adotada para integrar sistemas independentes em que a troca de informações é necessária para a conclusão da tarefa desejada. Existem duas implementações de *web services*: SOAP e REST. Neste trabalho, foi optado pela utilização da implementação REST devido à sua simplicidade.

2.2.8 REST

O REST é um protocolo de comunicação baseado no HTTP que não restringe o formato das mensagens tendo apenas restrições sobre o comportamento dos componentes envolvidos. Tem como principal característica sua flexibilidade. Como o formato da mensagem não é especificado, os mais diversos padrões podem ser adotados, desde JSON, XML e texto puro. De modo geral, *Web Services* que implementam REST são consideravelmente mais simples e, conseqüentemente, mais rápidos.

2.2.9 Md5

Md5 é uma função de dispersão criptográfica, sendo conhecida como *hash* criptográfica. Composta de 128 bits, onde é criada a partir de um sequência de caracteres, resultando em uma hash única para cada sequência, como demonstrado na Figura 2.2.



Figura 2.2: Exemplo de md5.

Capítulo 3

Revisão Bibliográfica

Visando ter um embasamento teórico sobre os assuntos relacionados a proposta, alguns artigos fundamentais serão apresentados neste capítulo.

Em [Filho and Wörndl, 2015], foi proposta uma abordagem para elaboração de “menu” eletrônico para restaurantes que visava minimizar o tempo de escolha do pedido utilizando as informações das interações do usuário com o sistema para alterar a ordem em que os pedidos eram mostrados na interface do sistema. O trabalho levou em conta a hipótese de relação entre o tempo de sessão e a satisfação do usuário. Um baixo tempo demonstrou que o usuário encontrou de maneira eficiente o que desejava, relacionando esta informação com o *feedback* do usuário em questão. A inovação no sistema mostrou resultados interessantes, visto que a taxa de escolha de novos pratos foi de 1,4 para 2,4. Entretanto, o trabalho apresentou tempo limitado de avaliação (apenas 2 semanas).

Em [Elahi et al., 2015], foi proposto a criação de um sistema de recomendação de receitas que poderiam ser de interesse do usuário, com o objetivo de exaltar a satisfação dos mesmos, através da utilização do *feedback* pós receita para melhorar uma futura recomendação. O sistema foi baseado em aprendizado de curto e longo prazo. A curto prazo o sistema se baseou em ingredientes e equipamentos que o usuário possuía, e a longo prazo, no gosto do usuário (o que gostava de comer ou cozinhar). A utilização de *feedbacks* é o ponto principal deste estudo, o qual era fornecido aos usuários após a utilização da receita, e assim os indivíduos avaliavam o resultado final.

A abordagem presente em [Košir et al., 2014] é um tanto diferente das demais, pois foi proposta a utilização de uma teoria de psicologia para modelar o comportamento dos usuários. Esta é conhecida como *Theory of Planned Behavior (TPB)*. A *TPB* é baseada em um formulário de perguntas, nas quais as respostas serão utilizadas como as características para modelar o usuário e assim aplicar um classificador linear como o *Linear Discriminant Analysis (LDA)*. O *LDA* é aplicado em um sistema de recomendação de filmes baseado no gênero da produção e perfil do usuário. Uma desvantagem deste trabalho foi a pequena base de dados (apenas 28 indivíduos), fato que não permite generalizar os resultados alcançados com “boa” confiança para uma grande população.

Otimizar os resultados de motores de busca é o objetivo do trabalho apresentado em [Sugiyama et al., 2004]. Neste artigo foi proposto a personalização de *links* e conteúdo. Esse modelo apresentou uma nova abordagem de captura de informações do usuário sem que o mesmo tivesse que fornecer estas informações, por meio de *feedbacks*, ou outras formas de coleta. Esta abordagem está relacionada com o perfil do usuário e suas consultas ao sistema. Estas informações foram armazenadas e aplicadas para aprimorar os resultados da busca quando o

usuário retornasse ao sistema, promovendo o aperfeiçoamento da experiência do usuário, ou seja, aperfeiçoar a satisfação do usuário em relação a utilização do sistema.

Um sistema de recomendação fundamentado no comportamento do usuário, tendo como princípio ser utilizado na rede social Google Plus [Google Inc., 2011], foi proposto em [Zhao et al., 2015]. O estudo foi baseado em filtros colaborativos e matriz de fatoração.

Estas técnicas são aplicadas em casos em que a quantidade de dados sobre os usuários é significativamente alta. As informações coletadas dos usuários foram, basicamente, as interações que eles tinham com o sistema, como: comentar, curtir, compartilhar e criar postagens. As informações foram utilizadas para prever o interesse a curto prazo e a longo prazo, através de uma matriz de fatoração.

Foi apresentado em [Constantinides et al., 2015] uma análise cognitiva para personalizar o visual e aspectos de *design*, estando relacionada com *layouts* relevantes a forma de pagamento em *e-commerce* é apresentada. O sistema objetivou a adaptação em tempo real.

O Mercado Livre [Ebazar.com.br, 1999], um *e-commerce* muito popular no Brasil, apresenta uma modificação em seu layout baseado na última categoria visitada. A mesma consiste em apresentar os produtos da categoria específica na página principal do *site*. Com esta modificação simples é possível otimizar a interação do usuário no próximo acesso ao sistema.

Todos os estudos apresentados anteriormente estão relacionados com a proposta deste trabalho, pois envolvem a modelagem de usuários em sistemas, com o intuito de melhorar a interação dos mesmos, seja por meio de sistemas de recomendações ou alterações de interfaces.

Capítulo 4

Proposta

Neste capítulo, são detalhadas todas as etapas da proposta. Tendo em vista uma organização linear e adequada das etapas, elas são apresentadas em sequência.

A proposta consiste em modificar a apresentação dos anúncios em um *e-commerce* tendo como objetivo melhorar a satisfação do usuário ao utilizar o sistema e, conseqüentemente, elevar o tempo de permanência no portal, utilizando-se de técnicas de aprendizado de máquina para analisar e classificar os usuários do sistema, de maneira a escolher um *layout* de apresentação de anúncio mais adequado aquela classe de usuário.

Foi definido que os usuários podem ser classificados nas categorias visual e textual, em que, a classe visual é representada pelos indivíduos que interagem mais com elementos visuais, e a classe textual, obviamente, pelos que interagem mais com elementos textuais.

No primeiro acesso, cada usuário é identificado unicamente por uma *hash* (Seção 2.2.9), que fica armazenada em um *cookie* (Seção 2.2.2) e dados referentes ao comportamento do usuário como tempo de sessão, interação do mouse, etc, são armazenados. A classificação é feita a partir do momento que um usuário conhecido realiza um novo acesso, ou seja, no primeiro acesso é feita a identificação do usuário e a coleta das informações relevantes ao comportamento, como este usuário não tem uma classificação definida o *layout* apresentado é genérico de modo a ser utilizado para análise das interações e coleta dos dados. De modo simultâneo a classificação um *feedback* (Seção 2.1.1) será proposto ao usuário de modo a analisar a satisfação referente a alteração da apresentação, este retorno do cliente será utilizado para aprimorar o classificador utilizando a técnica de aprendizado online (Seção 2.1.1) para isso.

Para o desenvolvimento da proposta é necessário que passos primordiais sejam cumpridos, como a análise do comportamento, coleta dos dados, extração de características, eliminação de ruído, entre outras descritas em detalhes neste capítulo.

O fluxograma apresentado na Figura 4.1 representa o fluxo geral da proposta do trabalho.

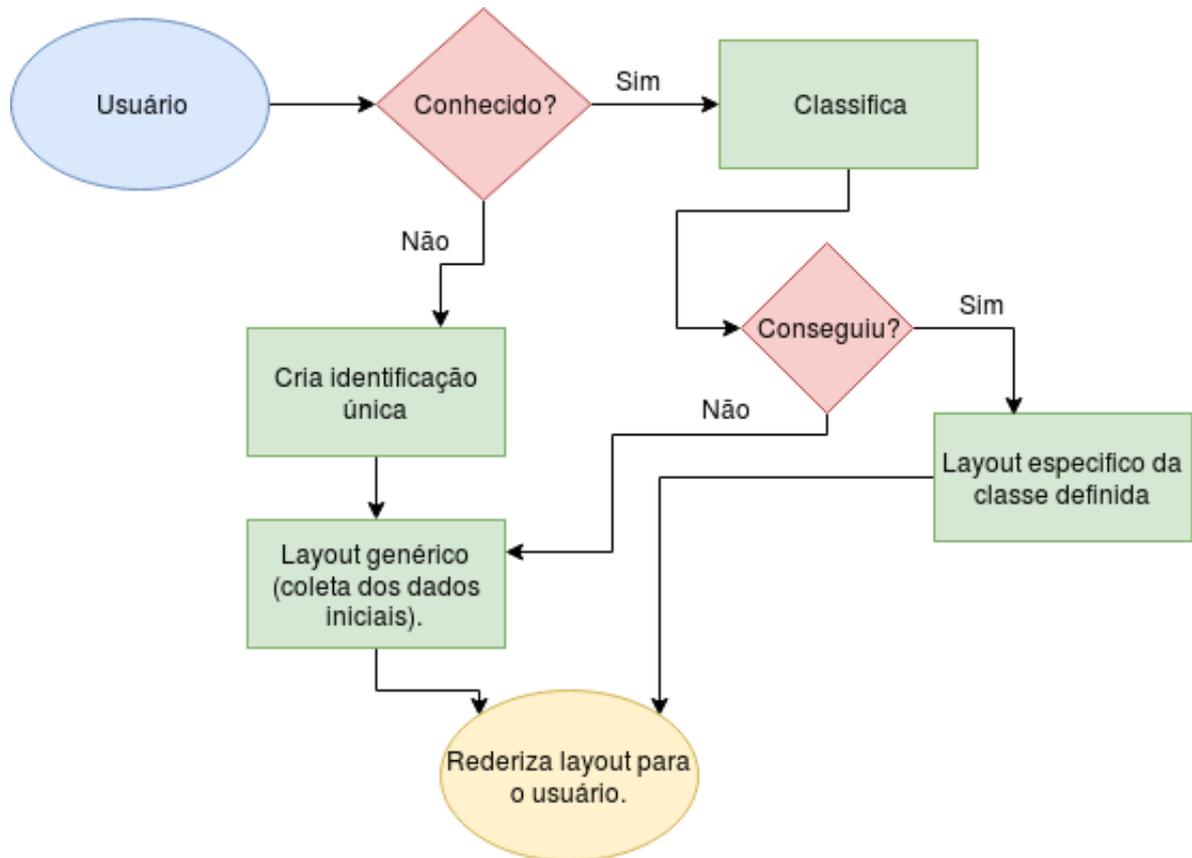


Figura 4.1: Diagrama geral da classificação.

4.1 Análise do comportamento

A interação do usuário com elementos da página será monitorada a partir de marcações prévias dos elementos, na qual os elementos visuais serão marcados como sendo do tipo V e elementos textuais como tipo T. O indicador do mouse é utilizado como a fonte de interação do sistema, esta interação é capturada através de *cliques*, tempo de interação, se está com o apontador em cima de algum elemento e contador de interações. Ressaltando que cada interação será associada ao tipo de elemento que esteve presente na ação.

4.2 Coleta dos dados

Após a captura das interações, como descrita na seção anterior, os dados serão armazenados em variáveis locais utilizando *javascript* (Seção 2.2.3) e enviados via *Web Service* (Seção 2.2.7) para o servidor com a intenção de serem armazenados de maneira definitiva. Como não é facilmente possível prever quando um usuário deixará a página, os dados serão enviados a cada 30 segundos para o servidor e este salva em disco. A Figura 4.2 apresenta um diagrama que exemplifica este ciclo.

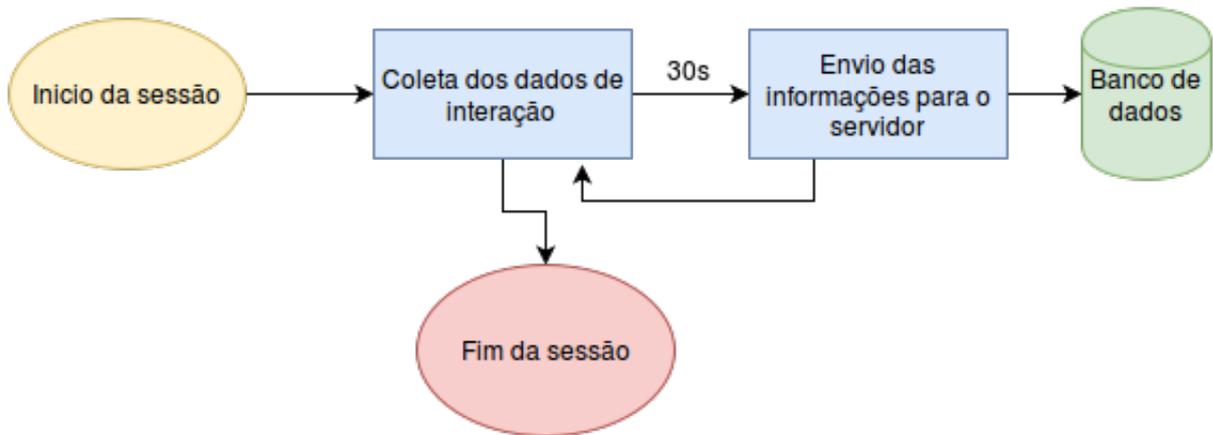


Figura 4.2: Diagrama do ciclo de coleta dos dados.

4.2.1 Identificação única

A identificação será criada a partir do momento que um usuário não identificado acesse uma página de visualização de anúncio. O número de usuários conhecidos será armazenado no servidor. Esta informação será utilizada de forma que este número é incrementado em 1 e o valor resultante é utilizado para a criação de uma *hash md5*, que é armazenada em um *cookie* no navegador do usuário, sendo utilizada para identificar este usuário em todos os momentos relevantes.

4.3 Extração de características

A extração de características envolve vários procedimentos para obtermos uma representação para que a classificação de um usuário se faça possível. Visando elucidar estes procedimentos esta seção é organizada em características, eliminação de ruído, normalização, base inicial e classificação.

4.3.1 Características

As características utilizadas foram escolhidas com base na experiência própria do autor que levou em consideração a facilidade de implementação e capacidade de discernimento de cada característica. A especificação das características está disposta na Tabela 4.1.

Tabela 4.1: Tabela de características.

Característica	Descrição
countA	Contador de interações com elementos do tipo V.
countB	Contador de interações com elementos do tipo T.
clickA	Contador de cliques com elementos do tipo V.
clickB	Contador de cliques com elementos do tipo T.
timeA	Tempo total de interações com elementos do tipo V.
timeB	Tempo total de interações com elementos do tipo T.
mediaA	Tempo médio entre o timeA e countA.
mediaB	Tempo médio entre o timeB e countB.
sessionTime	Tempo total da sessão.

4.3.2 Eliminação de ruído

Serão descartados dados inválidos detectados pela aplicação/implementação da proposta, visto que esses dados apresentam tempo de sessão muito curto ou valores de interação zerados, sendo portanto, possíveis erros da coleta de dados.

4.3.3 Normalização

A normalização atuará de forma a refinar os dados para que o comportamento do classificador seja o mais constante possível, ou seja, para que uma característica não influencie sozinha o processo de classificação. A técnica de normalização utilizada foi a *min-max*, explicada na Seção 2.1.2. Desta forma, todos os valores estarão normalizados em um intervalo [0, 1].

4.3.4 Base inicial

Uma base inicial classificada é necessária para dar início a classificação dos usuários, processo conhecido como *cold-start* em sistemas de recomendação [Kula, 2015]. Para criar a base, os dados dos usuários serão coletados em um primeiro momento e um critério para definir a classe respectiva de cada usuário será aplicado, este está especificado na subseção seguinte.

Classificação

A classe de cada usuário será definida neste momento como o tempo médio de interações com os elementos respectivos, ou seja, o cliente que apresentar o maior tempo médio de interações com elementos do tipo V será definido como um representante da classe V, da mesma forma para o caso onde os elementos são do tipo T.

4.4 Classificação de novos usuários

Quando uma página de anúncio for solicitada ao servidor, a identificação do usuário será enviada para a aplicação responsável por toda implementação da proposta do trabalho. O usuário será classificado pelo classificador SVM 2.1.1 bastante utilizado na literatura pois apresenta bons resultados para diversos problemas, a classe específica do usuário será retornada a aplicação, em caso de um usuário novo a classe retornada é vazia e o *layout* apresentado será o genérico.

4.5 Alteração do layout

Após obter a classe que o usuário está relacionado, o *layout* de apresentação do anúncio será alterado para o que apresente a melhor representação possível para este usuário, tendo em vista uma melhor interação do cliente com o sistema. Existirão três *layouts* disponíveis: genérico, visual e textual.

4.5.1 Genérico

O *layout* genérico terá como função ser responsável pelo primeiro contato do usuário com o sistema. Nesta etapa será feita a primeira coleta e análise dos dados relevantes sobre as interações, como não representa especificamente uma classe é chamado de genérico. É composto



Figura 4.4: Modelo de layout visual, no qual elementos vermelhos são do tipo V e azuis do tipo T.

4.5.3 Textual

Esse *layout* terá o objetivo de exaltar os elementos do tipo T, que equivalem a componentes textuais. A mudança apresentada é a mesma que ocorre com os elementos visuais descrita na Seção 4.5.2, com a diferença que está ocorrendo para os elementos do tipo T. Temos a Figura 4.5 como uma exemplificação.

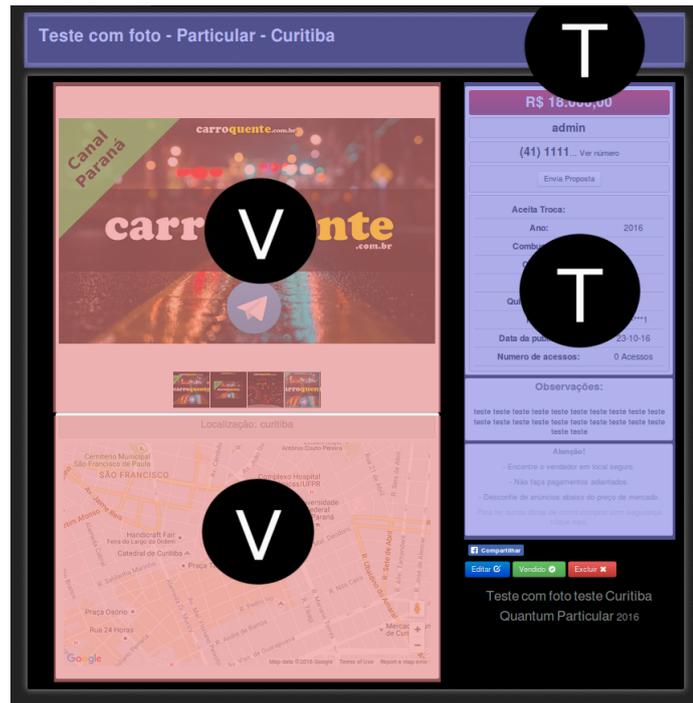


Figura 4.5: Modelo de layout textual, no qual elementos vermelhos são do tipo V e azuis do tipo T.

4.6 Feedback

O *feedback* será apresentado ao usuário após 30 segundos de contato com a nova apresentação, como ilustra a Figura 4.6. A definição do tempo para apresentação do *feedback* e aparência é de escolha do autor. Existem duas possibilidades para o retorno: positivo ou negativo. Um retorno positivo será tratado como uma mudança adequada e o usuário está satisfeito. Caso contrário, para o retorno negativo entende-se que o usuário está insatisfeito com a mudança.

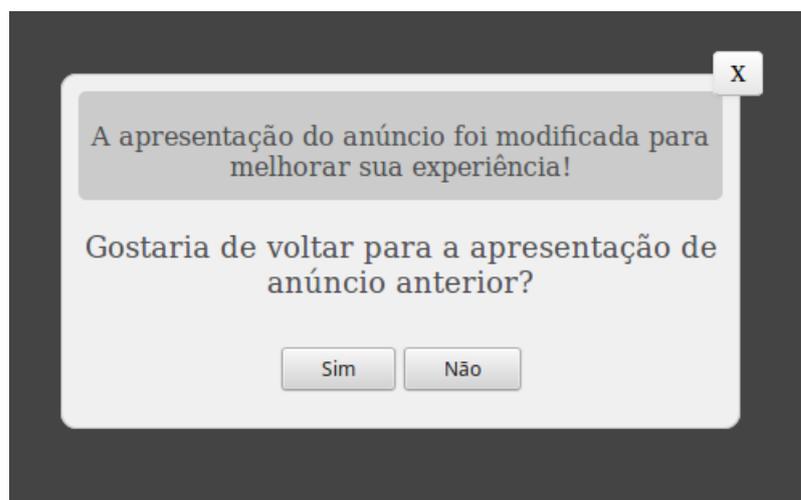


Figura 4.6: Modelo de feedback.

4.7 **Aprendizado *Online***

O aprendizado online é feito em cima das duas possibilidades de retorno do *feedback*, a proposta trata ambas de forma semelhante. Em um caso de retorno positivo os dados e a classificação serão inseridos no treinamento do classificador, desta forma o algoritmo estará utilizando estes dados para aprimorar o seu modelo. Caso o retorno seja negativo, a classe predita será invertida, ou seja, se foi predito que tal usuário seria da classe visual, a mesma passará a ser textual, e será inserida no classificador, ressaltando que o usuário que relatou o *feedback* negativo não será mais classificado pelo sistema por definição de projeto.

Capítulo 5

Validação

Este capítulo apresenta os resultados obtidos com a experimentação que foi efetuada sobre a proposta deste trabalho. Visando permitir a reprodutibilidade de toda experimentação reportada aqui, tanto os dados coletados da interação dos usuários com o *e-commerce* bem como a implementação da proposta (i.e., uma aplicação) estão disponíveis em [Burda, 2016] .

5.1 Experimentação

Pela facilidade técnica e a necessidade da criação de uma base de dados, um portal de classificados de veículos [Burda, 2013] forneceu sua plataforma como base para a realização da experimentação. O *site* disponibilizou todas as informações necessárias para análise, como tempo de sessão, entre outras.

Uma aplicação foi desenvolvida em *Flask* (Seção 2.2.5) para auxiliar na experimentação, na qual esta tem todas as funções necessárias para realizar as tarefas que são fundamentais no processo, como armazenamento dos dados coletados, resultados dos *feedbacks*, criar identificadores únicos e classificar usuários. Para a comunicação com outros sistemas a aplicação disponibiliza um *webservice* (Seção 2.2.7) que permite o acesso a todas essas funções a partir de outros sistemas. Esta implementação está disponível em [Burda, 2016].

A coleta de informações foi baseada em funções da biblioteca *jquery* 2.2.3 que representam interações do usuário com o sistema. Na qual utiliza o *webservice* 2.2.7 para transmitir estas informações a aplicação central descrita anteriormente.

O período de coleta das informações foi de aproximadamente três semanas para o sistema original, sem a aplicação da proposta deste trabalho. O mesmo período de tempo foi respeitado para a versão modificada do sistema em que a proposta de modo geral estava em vigor.

5.2 Resultados

Os resultados estão organizados de modo em que os valores iniciais pertencem a primeira fase de experimentação, em que apenas a coleta das interações estava disponível, seguido pela segunda fase, que se refere a aplicação plena da proposta deste trabalho. Objetiva-se obter uma análise comparativa entre essas fases.

Como no intervalo de tempo os valores podem ser bem distintos, o intervalo está limitado em valores entre 0 a 30 minutos, ou seja, valores fora do intervalo foram descartados. Outro critério de exclusão utilizado é a necessidade do usuário ter efetuado dois ou mais acessos

no período analisado. No entanto, no caso de mais de dois acessos ao sistema, apenas os dois primeiros acessos são utilizados.

5.2.1 Primeira fase

Os resultados apresentados são referentes a primeira fase da experimentação, na qual apenas a coleta de informações estava em vigor, para a obtenção dos dados de controle.

A Figura 5.1 apresenta um gráfico referente a dispersão dos indivíduos em razão do tempo de duração do primeiro e do segundo acesso, representados pelos eixos x e y, respectivamente. A Tabela 5.1 apresenta os valores utilizados para a geração do gráfico na Figura 5.1, seguida pela Tabela 5.2, que apresenta informações relevantes sobre o conjunto de dados.

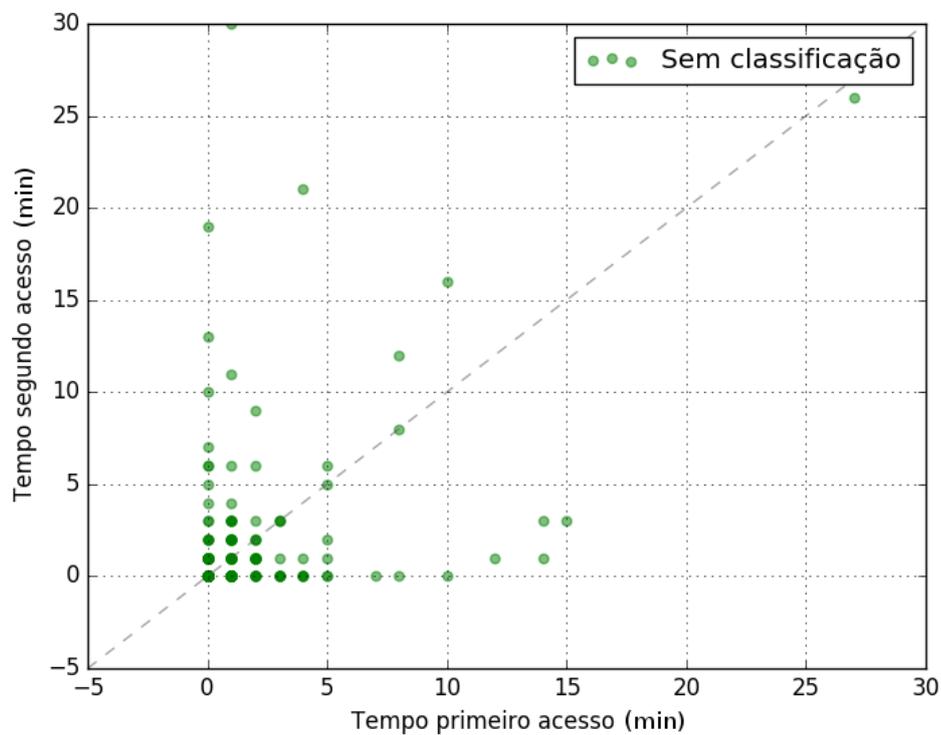


Figura 5.1: Gráfico de dispersão entre o primeiro e segundo acesso sem classificação.

Tabela 5.1: Valores da primeira fase em minutos referentes ao primeiro acesso.

Dados do primeiro acesso - Primeira fase									
1.0	0.5	0.5	4.0	8.0	1.0	12.0	0.5	0.5	0.5
3.0	1.0	0.5	0.5	1.5	0.5	1.0	1.5	1.5	1.0
0.5	0.5	0.5	2.5	2.0	0.5	1.0	0.5	0.5	0.5
0.5	3.5	0.5	2.5	1.0166	0.5	0.5	10.0	0.5	1.0
5.5	2.0	2.5	7.0	5.0	0.5	1.0	0.5	1.0	1.5
0.5	14.5	1.0	0.5	1.0	0.5	0.5	0.5	1.0	1.5
0.5	1.0	1.0	0.5	1.0	0.5	0.5	4.0	1.0	1.0
8.0	0.5	1.0	0.5	5.0	0.5	1.5	0.5	0.5	3.5
4.0	2.5	4.0	0.5	3.5	1.0	0.5	0.5	0.5	0.5
2.5	14.0	1.5	0.5	1.0	2.0	1.0	5.9833	10.9833	0.5
2.0	1.0	1.5	1.0	0.5	27.65	1.5	0.5	1.5	0.5
1.5	3.5	1.0	1.0	0.5	0.5	2.0	3.0	0.5	0.5333
2.0	0.5	4.5	0.5	0.5	0.5	2.5	2.5	1.5	0.5
1.0	1.5	4.0	0.5	0.5166	1.0	0.5	0.5	1.5	0.5
0.5	0.5	0.5	1.5	3.5	2.5	0.5	1.5	0.5	5.0
0.5	0.5	0.5	1.5	5.0	1.0	0.5	2.0	1.5	1.0
3.0	0.5	2.0	2.5	0.5	1.5	15.9166	0.5	2.5	2.0
3.0	1.5	0.5	0.5	0.5	1.0	1.0	0.5	0.5	0.5
8.4666	1.0	2.0	0.5	0.5					

Tabela 5.2: Informações sobre a amostra da Tabela 5.1

Primeiro acesso	
Intervalo da amostra	[0-30]
Tamanho da amostra	186
Média	2.00
Variância	10.06
Desvio padrão	3.17

Tabela 5.3: Valores da primeira fase em minutos referentes ao segundo acesso.

Dados do segundo acesso - Primeira fase									
0.5	0.5	0.5	0.5	12.5	0.5	1.0	0.5	1.0	1.0
1.0	1.0	3.5	6.0	0.5	1.5	0.5	2.9833	16.5	3.0
0.5	0.5	1.5	1.5	0.5	3.5	2.0	1.0	1.0	1.5
3.0	0.5	1.0	26.1333	0.5	1.5	3.0	3.0	1.0	5.5
1.0	0.5	0.5	9.5	2.9833	1.0	0.5	2.5	1.0	0.5
0.5	0.5	1.0	0.5	0.5	0.5	2.0	1.0666	0.5	0.5
6.5	0.5	0.5	1.0	0.5	13.5	1.5	2.0	6.4333	21.0
1.5	1.0	0.5	1.0	1.5	8.9666	1.5	0.5	1.5	0.5
2.0	0.5	2.0	11.5	0.5166	1.0	0.5	0.5	0.5	1.0
2.5	0.5	1.5	0.5	3.0	0.5	2.0	1.0	0.5	0.5
0.5	4.4833	10.5166	2.0	0.5	1.5	0.5	0.5	3.0	6.0
0.5	1.0	6.5	0.5	0.5	0.5	0.5	1.5	0.5	2.0
3.5	0.5	0.5	1.0	0.5	2.0	0.5	0.5	0.5	1.0
1.0	5.5	0.5	0.5	1.5	0.5	0.5	0.5	0.5	3.5
3.0	0.5	1.5	0.5	0.5	0.5	1.5	0.5	0.5	3.5
1.0	0.5	1.0	0.5	0.5	0.5	7.65	4.0	3.0	0.5
0.5	0.5	0.5	1.0	0.5	0.5	2.5	1.0	0.5	0.5
2.0	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5
0.5	19.5	2.5	0.5	1.0					

Tabela 5.4: Informações sobre a amostra da Tabela 5.3

Segundo acesso	
Intervalo da amostra	[0-30]
Tamanho da amostra	186
Média	2.08
Variância	12.90
Desvio padrão	3.59

Tabela 5.5: Valores da segunda fase em minutos referentes ao primeiro acesso.

Dados do primeiro acesso - Segunda fase									
0.5	1.0	1.0	0.5	1.0	1.0	1.5	5.5	1.0	0.5
0.5	1.0	1.0	1.0	0.5	3.0	0.5	0.9833	5.0	0.5
2.5	0.5	0.5	1.0	0.5	8.0	0.5	1.0	0.5	1.0
0.5	0.5	0.5	0.5	9.0	1.5	2.5	0.5	0.5	2.5
0.5	0.5	1.5	1.5	0.5	0.5	1.0	0.5	0.5	0.5
1.0	2.0	1.0	1.5	1.0	0.5	1.0	0.5	0.5	0.5
0.5	3.0	0.5	0.5	4.0	0.5	1.5	0.5	0.5	1.5
0.5	1.0	0.5	2.0	23.5	0.5	0.5	0.5	0.5	6.5
0.5	0.5	1.5	0.5	1.0	2.0	1.5	0.5	0.5	1.5
0.5	0.5	0.5	7.0	1.5166	1.2833	6.0	0.5	1.0	0.5
2.5	1.5	0.5	2.0	0.5	0.5	0.5	12.9666	1.5	0.5
1.0	6.0	1.5	1.5	9.5	2.0	0.5	1.0	1.5	0.5
0.5	2.0	6.9166	0.5	0.5	1.0	0.5	0.8666	1.0	3.0
0.5	4.5	0.5	5.0	0.5	0.5	1.0	0.5	0.5	1.0
3.5	0.5	1.0	1.5	1.0	1.0	5.5	6.5833	0.5	0.5
4.5	0.5	1.0	0.5	1.0	0.5	1.5	1.5	1.5	1.5
1.0	0.5	1.5	3.0	0.5	0.5	13.5	0.5	0.5	0.5
1.0	0.5	0.5	0.5	0.5	4.5	1.0	0.5	2.5	1.5
1.5	1.0	0.5	1.1333	0.5	1.5	1.0	0.5	2.0	0.5
0.5	0.5	2.0	1.0	0.5	3.5	0.5	0.5	0.5	1.0
0.5	2.0	2.5	0.5	0.5	0.5	2.0	1.0	0.5	0.5
0.5	0.5	8.5	0.5	1.0	1.5	0.5	1.5	0.5	20.0
0.5	0.5	1.5	0.5	0.5	0.5666	0.5	2.0	1.5	12.0
1.0	0.5	0.5	0.5						

Tabela 5.6: Informações sobre a amostra da tabela 5.5

Primeiro acesso	
Intervalo da amostra	[0-30]
Tamanho da amostra	234
Média	1.69
Variância	7.72
Desvio padrão	2.78

Tabela 5.7: Valores da segunda fase em minutos referentes ao segundo acesso.

Dados do segundo acesso - Segunda fase									
0.5	0.5	0.5	0.5	0.5	0.5	1.0	1.5	1.0	1.0
1.0	1.0	1.5	0.5	0.5	1.0	0.5	0.5	1.5	0.5
2.5166	1.0	0.5	0.5	0.5	2.0	0.5	1.0	0.5	4.0
1.5	1.0	0.5	1.0	8.0	1.0	1.0	0.5	4.5	3.5
1.0	4.75	1.5166	0.5	0.5	1.5	0.5	0.5	0.5	1.0
2.5	2.0	1.0	1.0	1.5	27.5	1.0	1.0	0.5	0.5
1.0	10.0	2.5	1.5	1.0	1.0	0.5	0.5	1.0	1.0
6.0	0.5	1.0	4.5	0.5	0.5	0.5	0.5	3.0	1.5
1.5	1.0	6.4166	0.5	0.5	1.5	0.5	1.5	0.5	3.5
0.5	0.5	0.5	0.5	0.5333	0.5	3.5	0.5	3.0	28.5
0.5	0.5	13.5	0.5	1.0	0.5	0.5333	0.5	0.5	1.0
4.0	5.0	1.0	1.0	0.5	5.0166	1.0	3.5	0.5	1.5
1.9333	0.5	0.5	0.5	0.5	0.5	0.5	0.5	4.0	12.5
0.5	0.5	0.5	1.0	0.5	0.5	1.5	1.0	0.5	1.0
1.0	1.0	4.5	0.5	2.5	0.5	1.5	0.5	0.5	0.5
0.5	3.0	3.5	1.5	0.5	11.5	3.0	0.5	1.0	0.5
0.5	24.0	0.5	0.5	0.5	0.5	0.5	0.5	0.5	3.0
1.5	0.9833	24.0	1.0	0.5	0.5	1.5	0.5333	0.5	1.0
3.5	0.5	1.5	0.5	1.0	0.5	1.0	1.0	0.5	3.5
2.0	1.0	0.5	1.0	0.5	2.0	0.5	0.5	0.5	2.5
1.0	1.0	1.0	1.0	8.5	3.5	1.0	4.0	0.5	1.5
0.5	5.5	1.0	1.5	0.5	0.5	2.4166	0.5	2.0	1.5
1.5	0.5	3.0	1.0	1.0	0.8166	1.0	0.5	0.5	1.0
0.5	0.5	0.5	0.5						

Tabela 5.8: Informações sobre a amostra da tabela 5.7

Segundo acesso	
Intervalo da amostra	[0-30]
Tamanho da amostra	234
Média	1.91
Variância	13.80
Desvio padrão	3.71

5.3 Análise

Os resultados são analisados por meio de teste de hipótese [Dávila, 2016]. O teste de hipótese é utilizado para medir a significância estatística sobre um determinado conjunto de dados. Para obter um embasamento estatístico, dois testes de hipóteses foram realizados, um para a primeira fase e outro para a segunda fase da experimentação.

O teste unilateral esquerdo foi utilizado, ou seja, H_0 representa a situação onde o tempo médio do primeiro acesso é maior ou igual o tempo médio do segundo acesso, e H_1 representa o

oposto, que o tempo médio do primeiro é menor que o do segundo acesso. Uma confiança de 85% foi utilizada em todos os testes.

$$H_0 : U \geq U_0 \quad (5.1)$$

$$H_1 : U < U_0$$

Como a confiança é de 85%, temos que o nível de significância é 0,15 e o valor de Z mais próximo é $-1,04$. Ao realizar o teste e encontrar um valor maior que $-1,04$ para Z a hipótese H_0 é confirmada, caso contrário H_0 é negada e H_1 é confirmada.

5.3.1 Teste de Hipótese para a primeira fase

Cálculo de Z [Dávila, 2016] para a primeira fase da experimentação, obtemos

$$Z = (2.00 - 2.08)/(3.17/\sqrt{186}) = -0.3669$$

Como o valor obtido é maior que $-1,04$ a hipótese H_0 foi confirmada. Portanto, o tempo médio do primeiro acesso é maior que o segundo estatisticamente.

5.3.2 Teste de Hipótese para a segunda fase

Cálculo de Z [Dávila, 2016] para a segunda fase da experimentação, obtemos

$$Z = (1.69 - 1.91)/(2.78/\sqrt{234}) = -1.2107$$

Como o valor obtido é menor que $-1,04$ a hipótese H_0 é negada, ou seja, H_1 é confirmada na qual afirma que o tempo médio do segundo acesso é maior que o do primeiro.

Pela definição do teste aplicado, podemos inferir que existe uma significância estatística sobre a segunda fase da experimentação que não estava presente na amostra coletada na primeira fase, na qual a proposta não estava em vigor.

5.3.3 Dificuldades

Devido a inúmeras dificuldades enfrentadas na experimentação, esta sessão se faz necessária para que seja de conhecimento do leitor as situações adversas encontradas. A principal dificuldade foi a coleta dos dados, pois a coleta de dados reais envolve a dificuldade de tratamento para os incontáveis dispositivos diferentes presentes no mercado que podem acessar um *website*. Este contratempo foi superado com a utilização do *framework jquery 2.2.3*. Outra questão que teve que ser contornada, é referente aos acessos criados por sistemas automáticos que tem a capacidade de acessar *websites* para a coleta de informações. Como a proposta é referente a pessoas, estas informações de comportamento capturadas foram descartadas utilizando o tempo de sessão e os contadores de interações como limitadores, onde um valor zerado resulta no descarte dos dados. A grande maioria dos usuários classificados não respondeu o *feedback*, ou seja, o mesmo foi ignorado e fechado sem que uma resposta fosse selecionada.

Por último, o maior empecilho foi referente a determinar o momento que um usuário fecha a página, para que o envio das informações ao servidor fosse efetuado. De modo a solucionar este problema, foi optado pelo envio contínuo das informações em um período de tempo recorrente, ou seja, as informações foram enviadas a cada 30 segundos de modo que a última remessa de dados recebida seria a armazenada.

5.4 Discussão

O engajamento do usuário pode ser definido como a maneira que a interação com o conteúdo apresentado é feita. Um alto grau de engajamento pode levar a um tempo de sessão maior, onde o usuário passa mais tempo interagindo com o sistema. Tendo em vista a definição apresentada o questionamento é até que ponto o engajamento pode ser favorecido por uma apresentação de conteúdo diferenciada que visa agradar o usuário exaltando os elementos que apresentam maior interação. A mudança da apresentação do conteúdo tem um fator massivo no aumento do engajamento do cliente, pois o conteúdo será apresentado a partir de elementos que obtiveram maior engajamento deste usuário, ou seja, são elementos que o usuário interagiu mais e por este fator é possível que exista um aumento no tempo de sessão.

O baixo percentual de contribuição dos usuários relevantes aos *feedbacks* merece uma breve discussão, tendo em vista que a resposta necessitava de apenas uma interação a qual a escolha entre dois botões era necessária. Por mais fácil que seja a interação, a mesma depende da boa vontade do cliente de realizá-la. Desta forma, a falta de contribuição pode ser relacionada ao simples fato que os usuários não fazem ideia da capacidade que esta simples contribuição pode ajudar na melhoria do sistema.

Por mais baixo que seja o percentual de contribuições com o *feedback*, a maioria dos usuários optou por voltar ao modo de apresentação anterior. Com isto, a dúvida que fica é o que motivou este resultado. Uma explicação possível seria que os usuários estão acostumados com uma interface, estão adaptados a sua forma de apresentar o conteúdo, e quando a interface é adaptada aos usuários a zona de conforto é removida e, quando a opção de voltar a esta zona está disponível, a mesma é escolhida de forma inquestionável.

Capítulo 6

Conclusão

Com base nos resultados apresentados na Seção 5.2, em especial nos testes de hipótese, é possível afirmar com uma confiança de 85% que a proposta deste trabalho foi confirmada estatisticamente para os dados amostrados. Desta forma, o tempo de sessão do segundo acesso no qual já estava em vigor a classificação do usuários foi superior ao tempo de sessão no primeiro acesso. Visto isto, a solução proposta neste trabalho é plausível e viável para aplicações web, visando melhorar a interação dos usuários e, conseqüentemente, obter um tempo de sessão maior.

Devido ao intervalo de tempo de coleta dos dados do usuário (30 segundos – grande no contexto do trabalho), há uma dificuldade de interpretação dos gráficos. Desta forma, o agrupamento de pontos dificultou a interpretação dos gráficos, devendo ser estudado outras formas de amostragem e tempo de coleta para superar essa dificuldade.

6.1 Trabalhos Futuros

Esta seção visa informar alguns trabalhos futuros que podem ser desenvolvidos de forma a complementar este trabalho.

Como a alteração do *layout* pode influenciar diretamente a interface do sistema, uma abordagem utilizando teste A/B [Zygo, 2016] poderia resultar em um *layout* mais eficiente para os usuários, na qual todas as modificações efetuadas a partir do *layout* base passariam por uma avaliação. Seria interessante estudar se é possível comparar o desempenho deste trabalho com sistema de recomendação, que é capaz de recomendar algo ao usuário no qual resulta em um aumento do tempo de sessão, desta maneira, o usuário é incentivado a visitar outros produtos que podem ser de seu interesse.

Além disso, é necessário, como trabalho futuro, a pesquisa de métodos mais eficientes para o envio das informações coletadas ao servidor, de modo que, apenas ao final da sessão, os dados sejam enviados. Desta forma, os problemas criados pela coleta dos dados feita em intervalos de tempo seriam solucionados.

Referências Bibliográficas

- [Bishop, 2007] Bishop, C. (2007). *Pattern Recognition and Machine Learning*. Springer-Verlag New York.
- [Brasil, 2016] Brasil, P. (2016). Pesquisa revela que mais de 100 milhões de brasileiros acessam a internet. <http://www.brasil.gov.br/ciencia-e-tecnologia/2016/09/pesquisa-revela-que-mais-de-100-milhoes-de-brasileiros-acessam-a-internet>. Acessado em 21/11/2016.
- [Burda, 2013] Burda, R. L. (2013). Carro quente. <http://www.carroquente.com.br/>, acessado em novembro de 2016.
- [Burda, 2016] Burda, R. L. (2016). Ihc to layout. <https://github.com/renankof/ihc2layout>, acessado em dezembro de 2016.
- [Constantinides et al., 2015] Constantinides, A., Belk, M., Germanakos, P., and Samaras, G. (2015). The personacheck system for personalizing m-commerce checkout processes. In *16th IEEE International Conference on Mobile Data Management (MDM'15)*, volume 1, pages 303–306. "Qualis/Capes CC-A2".
- [Crockford, 2006] Crockford, D. (2006). Json - javascript object notation - rfc4627. <https://tools.ietf.org/html/rfc4627>. acessado em 16/1/2017.
- [Dávila, 2016] Dávila, V. H. L. (2016). Teste de hipóteses. http://www.ime.unicamp.br/~hlauchos/Inferencia_Hip01.pdf. acessado em 16/1/2017.
- [Ebazar.com.br, 1999] Ebazar.com.br (1999). Mercado livre. <http://www.mercadolivre.com.br/>. acessado em novembro de 2016.
- [Eich, 1995] Eich, B. (1995). Javascript. <https://pt.wikipedia.org/wiki/JavaScript>. acessado em 16/1/2017.
- [Elahi et al., 2015] Elahi, M., Ge, M., Ricci, F., Fernández-Tobías, I., Berkovsky, S., and David, M. (2015). Interaction design in a mobile food recommender system. In *Joint Workshop on Interfaces and Human Decision Making for Recommender Systems (IntRS 2015)*. co-located with ACM Conference on Recommender Systems (RecSys 2015).
- [Filho and Wörndl, 2015] Filho, P. H. A. and Wörndl, W. (2015). An adaptive electronic menu system for restaurants. In *RecSys*. Qualis/Capes CC-A2.
- [Google Inc., 2011] Google Inc. (2011). Google plus. <https://plus.google.com/>. acessado em novembro de 2016.

- [ITU, 2016] ITU (2016). Measuring the information society report. Technical Report ISBN 978-92-61-21431-9, International Telecommunication Union, CH-1211 Geneva Switzerland.
- [Kořir et al., 2014] Kořir, A., Odić, A., Tkalčić, M., and Svetina, M. (2014). Human decisions in user modeling: motivation, procedure and example application. In *22nd Conference on User Modeling, Adaptation, and Personalization (UMAP'14)*, pages 1–14. special session - Emotions and Personality in Personalized Services (EMPIRE'14).
- [Kula, 2015] Kula, M. (2015). Metadata embeddings for user and item cold-start recommendations. In *2nd Workshop on New Trends in Content-Based Recommender Systems*, Vienna, Austria.
- [Osório, 1999] Osório, F. (1999). Redes neurais - aprendizado artificial. *Forum de I.A.* .
- [Pedregosa et al., 2011] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- [Resing, 2006] Resing, J. (2006). Jquery. <https://jquery.com/>. acessado em 16/1/2017.
- [Ronacher, 2010] Ronacher, A. (2010). Flask (a python microframework). <http://flask.pocoo.org/>. acessado em 16/1/2017.
- [Rossum, 1999] Rossum, G. V. (1999). Python. <https://www.python.org/>. acessado em 16/1/2017.
- [scikit learn, 2012] scikit learn (2012). Stochastic gradient descent. <http://scikit-learn.org/stable/modules/sgd.html>, acessado em novembro de 2016.
- [Scikit-learn, 2012] Scikit-learn (2012). Support vector machines. <http://scikit-learn.org/stable/modules/svm.html>. acessado em novembro de 2016.
- [Sugiyama et al., 2004] Sugiyama, K., Hatano, K., and Yoshikawa, M. (2004). Adaptive web search based on user profile constructed without any effort from users. In *23th International Conference on World Wide Web (WWW)*, pages 675–684. Qualis/Capes CC-A1.
- [Wikipedia, 2016] Wikipedia (2016). Retroalimentação. <https://pt.wikipedia.org/wiki/Retroalimenta%C3%A7%C3%A3o>. Acessado em 16/01/2017.
- [Wikipedia, 2017a] Wikipedia (2017a). Aprendizado de máquina. https://pt.wikipedia.org/wiki/Aprendizado_de_m%C3%A1quina. Acessado em 16/01/2017.
- [Wikipedia, 2017b] Wikipedia (2017b). Online machine learning. https://en.wikipedia.org/wiki/Online_machine_learning. Acessado em 16/01/2017.
- [Zadrozny, 2010] Zadrozny, B. (2010). Aprendizado de máquina. <http://www2.ic.uff.br/~bianca/aa/>. Acessado em 16/01/2017.
- [Zhao et al., 2015] Zhao, Z., Cheng, Z., Hong, L., and Chi, E. H. (2015). Improving user topic interest profiles by behavior factorization. In *24th International Conference on World Wide Web (WWW)*, pages 1406–1416. Qualis/Capes CC-A1.

[Zygo, 2016] Zygo (2016). Teste a/b. <http://zygon.digital/blog/teste-ab-o-que-e-por-que-fazer/>. acessado em 25/1/2017.