

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE SÃO PAULO - PUC-SP
PROGRAMA DE PÓS-GRADUADOS EM ADMINISTRAÇÃO**

MILTON RUIZ RODRIGUES ALVES

**IMPORTÂNCIA DA AVALIAÇÃO SUBJETIVA DA PERCEPÇÃO DOS
USUÁRIOS EM ESTRATÉGIAS DE *CROWDVOTING*.**

DOUTORADO EM ADMINISTRAÇÃO DE EMPRESAS

**SÃO PAULO
2020**

MILTON RUIZ RODRIGUES ALVES

IMPORTÂNCIA DA AVALIAÇÃO SUBJETIVA DA PERCEPÇÃO DOS
USUÁRIOS EM ESTRATÉGIAS DE *CROWDVOTING*.

Tese apresentada à Banca Examinadora da Pontifícia Universidade Católica de São Paulo, como exigência parcial para obtenção do título de Doutor em Administração sob a orientação do Professor Doutor Belmiro do Nascimento João.

SÃO PAULO
2020

BANCA EXAMINADORA

Autorizo exclusivamente para fins acadêmicos e científicos, a reprodução total ou parcial desta Tese de Doutorado por processos de fotocopiadoras ou eletrônicos.

Assinatura:

Data:

E-mail:

FICHA CATALOGRÁFICA

Sistema para Geração Automática de Ficha Catalográfica para Teses e Dissertações com dados fornecidos pelo autor

RODRIGUES ALVES, MILTON RUIZ
IMPORTÂNCIA DA AVALIAÇÃO SUBJETIVA DA PERCEPÇÃO
DOS USUÁRIOS EM ESTRATÉGIAS DE CROWDVOTING. / MILTON
RUIZ RODRIGUES ALVES. -- São Paulo: [s.n.], 2020.
165p ; cm.

Orientador: Belmiro Nascimento João.
Tese (Doutorado em Administração)-- Pontifícia
Universidade Católica de São Paulo, Programa de
Estudos Pós-Graduados em Administração, 2020.

1. Crowdsourcing; . 2. Crowdvoting; . 3. Crow; e
WoM; . 4. UGC; Análise de Sentimentos.. I. João,
Belmiro Nascimento. II. Pontifícia Universidade
Católica de São Paulo, Programa de Estudos Pós
Graduados em Administração. III. Título.

CDD

“O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior- Brasil (CAPES) - Código de Financiamento 001. NÚMERO DO PROCESSO: 88887.147753/2017-00

“This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001. PROCESS NUMBER: 88887.147753 / 2017-00

AGRADECIMENTO

Ao professor Doutor Belmiro do Nascimento João, agradeço o acolhimento às minhas apreensões, dúvidas e a orientação, sempre tranquila, ao lidar com os desafios que este empreendimento nos apresentou. Muito obrigado pela orientação e apoio ao longo de minha formação acadêmica, participando de todas estas etapas, pelo mestrado e agora ao doutorado, muito obrigado.

Agradeço à Rita de Cássia e a equipe da PUC-SP, pela compreensão e apoio nesta jornada, o auxílio de vocês durante esta conquista foi essencial para o sucesso deste trabalho.

Agradeço à minha família pelo suporte e orientação, os quais foram vitais na busca do saber e para que eu pudesse chegar até aqui. Minha eterna gratidão pelo incentivo e exemplo dado, desde sempre, pelo qual incutiu em mim o desejo e o prazer na busca pelo conhecimento.

À minha irmã Joyce, agradeço o apoio e a prontidão em me socorrer nos apertos que surgiram ao longo desta fase e por ser um modelo de determinação e resiliência.

À Renata Cabral de Sousa agradeço o apoio e a paciência durante esta fase de muitas atividades, pelo seu incentivo e por compartilhar seu jeito leve frente às minhas ansiedades durante este trabalho. Obrigado pelo bom humor e pela ótima companhia que sempre me serve de refrigério nos momentos mais difíceis.

Mauricio Gavioli, Rogério Suzuki e Samuel Neves, amigos desde sempre, agradeço a paciência, a constante disponibilidade e as intermináveis discussões sobre teorias, métodos e caminhos de pesquisa que foram indispensáveis para a minha compreensão do tema e para manutenção da energia nesta empreitada.

Aos amigos Alessandro Nascimento, Eduardo Penterichi, Felipe Zacharias, Gabriel Lima, Jackson Carvalho, Jacques Carelli e Marcos Souza que constantemente me aconselham a buscar o equilíbrio entre o ensino secular e o divino, e que desta forma colaboram na formulação de um conceito equilibrado sobre minhas limitações e sobre a compreensão quanto à importância do conhecimento verdadeiro em nossas vidas.

Aos amigos Antonio Cocurullo e Thiago Gherardi que se mostraram como grandes mentores na caminhada do mundo corporativo, obrigado pelo incentivo e apoio à conclusão deste trabalho.

A todos vocês, minha mais sincera gratidão.

Milton Ruiz Rodrigues Alves

DEDICATÓRIA

Dedico este trabalho à minha família, por estar sempre disposta a me apoiar em todo e qualquer empreendimento que eu me proponha buscar. Por este apoio incondicional, agradeço a vocês. Milton Ruiz Alves, Vera Lúcia Rodrigues Alves e Joyce Ruiz Rodrigues Alves, muito obrigado, esta conquista é nossa.

A Jeová Deus, que sempre se mostra a disposição e coloca as pessoas certas para confortar e apoiar a cada fase da minha vida, e que assim o fez durante esta jornada.

RESUMO

O objetivo central deste estudo é analisar os impactos da estratégia de *crowdvoting* em varejos eletrônicos (*marketplaces*) a partir do entendimento de sua influência na percepção do cliente/usuário sobre o conteúdo gerado por seus pares, seu comportamento frente a diferentes culturas, ao comparar o cenário americano com o brasileiro, e assim avaliar a eficácia da utilização do *score* objetivo *versus* a percepção subjetiva da gestão do conteúdo gerado pelos usuários. Para isto este estudo visa a testar se o *crowdvoting* aumenta o engajamento e a fidelização dos usuários a um *marketplace*, se a percepção subjetiva do consumidor não acompanha a direção do *score* objetivo (nota de 1 a 5) e se em ambientes globalizados, os efeitos do *crowdvoting* se mantêm independentemente da localização geográfica de seus consumidores. O diferencial deste estudo é a aplicação de técnicas de análise de sentimentos conduzidas através de técnicas de *machine learning* sobre o conteúdo gerado pelos usuários destas redes. Para isto analisamos o sentimento do usuário em 94.595 reviews e os comparamos com a nota objetiva (*Review Score*) para três empresas norte americanas e uma empresa brasileira. Quanto as constatações, identificamos um descolamento importante da percepção do usuário em suas críticas subjetivas frente a nota objetiva, o que pode acarretar distorções na aplicação das estratégias e ao desgaste do relacionamento entre empresa e cliente. As análises também indicam que o comportamento da estratégia de *crowdvoting* atua de forma análoga em ambos os países e que o uso desta estratégia representa vantagens para o fortalecimento da marca, no processo decisório do consumidor e consequentemente no desempenho dos produtos.

Palavras-chave: *Crowdsourcing; Crowdvoting; e-WoM; UGC; Análise de Sentimentos.*

ABSTRACT

The main objective of this study is to analyze the impacts of the crowdvoting strategy in marketplaces from the understanding of its influence on the client/user perception about the content generated by their peers, their behavior towards different cultures when comparing the American and Brazilian scenario, and thus evaluate the effectiveness of the use of objective scoring versus the subjective perception of user-generated content management. To this end, this study aims to test whether crowdvoting increases user engagement and loyalty to a marketplace, whether subjective consumer perception does not follow the direction of the objective score (score 1 to 5) and whether in globalized environments the effects crowdvoting remains independent of the geographic location of its consumers. The differential of this study is the application of sentiment analysis techniques conducted through machine learning techniques on the content generated by users of these networks. We analyzed user sentiment in 94,595 reviews and compared them with the Review Score for three North American companies and one Brazilian company. As for the findings, we identified an essential detachment of the user's perception in their subjective criticism of the objective note, which may lead to distortions in the application of strategies and the wear and tear of the relationship between company and customer. The analyzes also indicate that the behavior of the crowdvoting strategy acts analogously in both countries and that the use of this strategy represents advantages for brand strengthening, consumer decision making, and, consequently, product performance.

Key Words: Crowdsourcing, Crowd voting, e-WoM, UGC, Sentiment-Analysis.

LISTA DE TABELAS

TABELA 1: CORRELAÇÃO DE PEARSON - AMOSTRA COMPLETA - AMAZON	62
TABELA 2: CORRELAÇÃO DE SPEARMAN - AMOSTRA COMPLETA – AMAZON.....	62
TABELA 3: CORRELAÇÃO DE KENDALL - AMOSTRA COMPLETA – AMAZON.....	63
TABELA 4: CORRELAÇÃO DE PEARSON - AMOSTRA COMPLETA – BESTBUY.....	64
TABELA 5: CORRELAÇÃO DE SPEARMAN - AMOSTRA COMPLETA – BESTBUY	65
TABELA 6: CORRELAÇÃO DE KENDALL - AMOSTRA COMPLETA – BESTBUY	66
TABELA 7: CORRELAÇÃO DE PEARSON - AMOSTRA COMPLETA – TOYRUS.....	67
TABELA 8: CORRELAÇÃO DE SPEARMAN - AMOSTRA COMPLETA – TOYRUS	68
TABELA 9: CORRELAÇÃO DE KENDALL - AMOSTRA COMPLETA – TOYRUS	68
TABELA 10: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEUTRA - AMAZON.....	70
TABELA 11: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEUTRA – AMAZON	71
TABELA 12: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEUTRA – AMAZON	71
TABELA 13: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA POSITIVA – AMAZON	72
TABELA 14: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA POSITIVA – AMAZON	73
TABELA 15: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA POSITIVA – AMAZON	74
TABELA 16: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEGATIVA – AMAZON.....	74
TABELA 17: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEGATIVA – AMAZON	75
TABELA 18: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEGATIVA – AMAZON	76
TABELA 19: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR SCORE OBJETIVO.	77
TABELA 20: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR CLASSIFICAÇÃO DA ANÁLISE DE SENTIMENTOS.	78
TABELA 21: REGRESSÃO LINEAR FEITA NO SOFTWARE R – VARIÁVEL DEPENDENTE REVIEW SCORE – AMAZON.....	80
TABELA 22: DE CORRELAÇÃO DE PEARSON – AMOSTRA NEUTRA – BESTBUY	81
TABELA 23: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEUTRA – BESTBUY	81
TABELA 24: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEUTRA – BESTBUY.....	82
TABELA 25: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA POSITIVA – BESTBUY	82
TABELA 26: TABELA DE CORRELAÇÃO DE SPEARMAN– AMOSTRA POSITIVA – BESTBUY	83
TABELA 27: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA POSITIVA – BESTBUY.....	84
TABELA 28: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEGATIVA – BESTBUY	84
TABELA 29: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEGATIVA – BESTBUY	85
TABELA 30: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEGATIVA – BESTBUY	86
TABELA 31: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR SCORE OBJETIVO.	87
TABELA 32: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR CLASSIFICAÇÃO DA ANÁLISE DE SENTIMENTOS	88
TABELA 33: REGRESSÃO LINEAR FEITA NO SOFTWARE R – VARIÁVEL DEPENDENTE REVIEW.RATING – BESTBUY.....	89
TABELA 34: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEUTRA – TOYRUS.....	90
TABELA 35: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEUTRA – TOYRUS	91
TABELA 36: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEUTRA – TOYRUS.....	92
TABELA 37: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA POSITIVA – TOYRUS.....	92
TABELA 38: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA POSITIVA – TOYRUS.....	93
TABELA 39: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA POSITIVA – TOYRUS.....	94
TABELA 40: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEGATIVA – TOYRUS	94
TABELA 41: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEGATIVA – TOYRUS.....	95
TABELA 42: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEGATIVA – TOYRUS	96
TABELA 43: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR SCORE OBJETIVO.	97
TABELA 44: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR CLASSIFICAÇÃO DA ANÁLISE DE SENTIMENTOS.	98
TABELA 45: REGRESSÃO LINEAR FEITA NO SOFTWARE R – VARIÁVEL DEPENDENTE REVIEW.RATING – TOYRUS.....	99
TABELA 46: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA COMPLETA – OLIST.....	100
TABELA 47: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA COMPLETA – OLIST	101
TABELA 48: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA COMPLETA – OLIST	102

TABELA 49: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEUTRA – OLIST	102
TABELA 50: TABELA DE CORRELAÇÃO DE SPEARMAN – AMOSTRA NEUTRA – OLIST.....	103
TABELA 51: TABELA DE CORRELAÇÃO DE KENDALL– AMOSTRA NEUTRA – OLIST.....	104
TABELA 52: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA POSITIVA – OLIST	104
TABELA 53: TABELA DE CORRELAÇÃO DE SPEARMAN– AMOSTRA POSITIVA – OLIST.....	105
TABELA 54: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA POSITIVA – OLIST.....	107
TABELA 55: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEGATIVA – OLIST.....	108
TABELA 56: TABELA DE CORRELAÇÃO DE SPEARMAN– AMOSTRA NEGATIVA – OLIST	109
TABELA 57: TABELA DE CORRELAÇÃO DE KENDALL – AMOSTRA NEGATIVA – OLIST	109
TABELA 58: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR SCORE OBJETIVO.	111
TABELA 59: TABELA DE QUANTIDADE MÉDIA DE CARACTERES POR CLASSIFICAÇÃO DA ANÁLISE DE SENTIMENTOS.	112
TABELA 60: REGRESSÃO LINEAR FEITA NO SOFTWARE R – VARIÁVEL DEPENDENTE REVIEW/SCORE – OLIST.....	113
TABELA 61: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA COMPLETA - AMAZON	116
TABELA 62: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA POSITIVA - AMAZON.....	116
TABELA 63: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEUTRA - AMAZON.....	117
TABELA 64: TABELA DE CORRELAÇÃO DE PEARSON – AMOSTRA NEGATIVA - AMAZON	117
TABELA 65: TABELA COMPARATIVA DE CORRELAÇÃO DE PEARSON – EMPRESAS AMERICANAS	124
TABELA 66: TABELA COMPARATIVA DE CORRELAÇÃO DE PEARSON – AMAZON X OLIST	124

LISTA DE FIGURAS

FIGURA 1: COMPORTAMENTO DO CONSUMIDOR	24
FIGURA 2: PIRÂMIDE DE VALOR DE MARCA	28
FIGURA 3: PROCESSO DECISÓRIO DE COMPRA.....	31
FIGURA 4: BOXPLOT DE DISTRIBUIÇÃO DE SCORE OBJETIVO X ANÁLISE DE SENTIMENTOS.....	77
FIGURA 5: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE.	78
FIGURA 6: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	79
FIGURA 7: BOXPLOT DE DISTRIBUIÇÃO DE SCORE OBJETIVO X ANÁLISE DE SENTIMENTOS.....	87
FIGURA 8: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE.	88
FIGURA 9: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	89
FIGURA 10: BOXPLOT DE DISTRIBUIÇÃO DE SCORE OBJETIVO X ANÁLISE DE SENTIMENTOS...	97
FIGURA 11: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE.	98
FIGURA 12: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	99
FIGURA 13: BOXPLOT DE DISTRIBUIÇÃO DE SCORE OBJETIVO X ANÁLISE DE SENTIMENTOS.	111
FIGURA 14: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE.	112
FIGURA 15: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	113
FIGURA 16: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE	119
FIGURA 17: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	119
FIGURA 18: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE.	120
FIGURA 19: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	120
FIGURA 20: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE.	121
FIGURA 21: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	121
FIGURA 22: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS POR SCORE	122
FIGURA 23: GRÁFICO DE BARRAS DE QUANTIDADE DE REVIEWS PELA VISÃO DA ANÁLISE DE SENTIMENTOS.	122

SUMÁRIO

<u>1 INTRODUÇÃO</u>	<u>15</u>
<u>1.1 PROBLEMA DE PESQUISA</u>	<u>16</u>
<u>1.2 OBJETIVO GERAL</u>	<u>18</u>
<u>1.3 JUSTIFICATIVA</u>	<u>20</u>
<u>2 REFERENCIAL TEÓRICO</u>	<u>23</u>
<u>2.1 COMPORTAMENTO DO CONSUMIDOR</u>	<u>24</u>
<u>2.2 MARCAS E SUA CONSTRUÇÃO</u>	<u>26</u>
<u>2.3 COMUNICAÇÃO INTEGRADA DE MARKETING</u>	<u>29</u>
<u>2.4 PROCESSO DECISÓRIO DO CONSUMIDOR</u>	<u>30</u>
<u>2.5 WOM (WORD OF MOUTH) E E-WOM</u>	<u>33</u>
<u>2.6 USER GENERATED CONTENT</u>	<u>35</u>
<u>2.7 INTELIGÊNCIA COLETIVA</u>	<u>38</u>
<u>2.8 CROWDSOURCING</u>	<u>39</u>
<u>2.8.1 TIPOLOGIA DE HOWE (2008)</u>	<u>39</u>
<u>2.8.1.1 CROWDFUNDING</u>	<u>40</u>
<u>2.8.1.2 CROWDVOTING</u>	<u>40</u>
<u>2.8.1.3 CROWDCREATION</u>	<u>40</u>
<u>2.8.1.4 CROWDWISDOM</u>	<u>41</u>
<u>2.8.2 TIPOLOGIA DE BRABHAM (2010)</u>	<u>41</u>
<u>2.8.2.1 DESCOBERTA E GERENCIAMENTO DE CONHECIMENTO</u>	<u>41</u>
<u>2.8.2.2 DIFUSÃO DE BUSCA</u>	<u>42</u>

2.8.2.3 PRODUÇÃO CRIATIVA COM VETOS	42
2.8.2.4 DISTRIBUIÇÕES DE TAREFAS QUE NECESSITEM DE INTELIGÊNCIA HUMANA	42
2.8.3 TIPOLOGIA DE SCHENK E GUITTARD (2009, 2011)	43
2.8.3.1 UTILIZANDO CROWDSOURCING PARA TAREFAS SIMPLES	43
2.8.3.2 CROWDSOURCING DE TAREFAS COMPLEXAS	44
2.8.3.3 CROWDSOURCING DE TAREFAS CRIATIVAS	44
2.8.4 TIPOLOGIA GEIGER, ROSEMANN E FIELT	45
2.9 SISTEMAS REPUTACIONAIS	45
2.10 CROWDVOTING E ESTRATÉGIA DE APLICAÇÃO	46
3 METODOLOGIA DE PESQUISA	49
3.1 DADOS	50
3.2 ANÁLISE DE SENTIMENTOS POR IA E MACHINE LEARNING	52
3.3 IDENTIFICAÇÃO DE USUÁRIOS E SIGILO DE DADOS SENSÍVEIS	55
3.4 TESTE DE CORRELAÇÃO	56
3.4.1 TESTE DE CORRELAÇÃO DE PEARSON	56
3.4.2 TESTE DE CORRELAÇÃO DE SPEARMAN	57
3.4.3 TESTE DE CORRELAÇÃO DE KENDALL	58
3.5 ANÁLISE DE SENTIMENTOS POR IA E MACHINE LEARNING	58
4 ANÁLISE DOS DADOS	60
4.1 AMOSTRA – AMAZON	61
4.1.1 AMOSTRA COMPLETA	61
4.2 AMOSTRA - BESTBUY	64
4.2.1 AMOSTRA COMPLETA	64
4.3 AMOSTRA - TOYRUS	66
4.3.1 AMOSTRA COMPLETA	66

4.4 ANÁLISE DE SENTIMENTO A PARTIR DE IA – AZURE MS E MEANINGCLOUD’S	69
4.4.1 AMOSTRA AMAZON	69
<u>4.4.1.1 AMOSTRA COM POLARIDADE NEUTRA</u>	<u>69</u>
4.4.1.2 AMOSTRA COM POLARIDADE POSITIVA	72
4.4.1.3 AMOSTRA COM POLARIDADE NEGATIVA	74
4.4.1.4 REGRESSÕES LINEARES MÚLTIPLAS	80
4.4.2 AMOSTRA BESTBUY	80
<u>4.4.2.1 AMOSTRA COM POLARIDADE NEUTRA</u>	<u>80</u>
4.4.2.2 AMOSTRA COM POLARIDADE POSITIVA	82
4.4.2.3 AMOSTRA COM POLARIDADE NEGATIVA	84
4.4.2.4 REGRESSÕES LINEARES MÚLTIPLAS	89
4.4.3 AMOSTRA TOYRUS	90
<u>4.4.3.1 AMOSTRA COM POLARIDADE NEUTRA</u>	<u>90</u>
4.4.3.2 AMOSTRA COM POLARIDADE POSITIVA	92
4.4.3.3 AMOSTRA COM POLARIDADE NEGATIVA	94
4.4.3.4 REGRESSÕES LINEARES MÚLTIPLAS	99
4.4.4 AMOSTRA OLIST (BR)	100
<u>4.4.4.1 AMOSTRA COMPLETA</u>	<u>100</u>
4.4.4.2 AMOSTRA COM POLARIDADE NEUTRA	102
4.4.4.3 AMOSTRA COM POLARIDADE POSITIVA	104
4.4.4.4 AMOSTRA COM POLARIDADE NEGATIVA	107
4.4.4.5 REGRESSÕES LINEARES MÚLTIPLAS	113
<u>4.5 ANÁLISE E DISCUSSÃO DOS RESULTADOS</u>	<u>114</u>
<u>5 CONCLUSÕES</u>	<u>126</u>
<u>6 REFERÊNCIAS BIBLIOGRÁFICAS</u>	<u>129</u>
<u>7 ANEXOS</u>	<u>137</u>

1 INTRODUÇÃO

Observamos as relações comerciais apresentarem consumidores alienados e passivos frente ao processo de escolha de produtos por séculos, tendo que se satisfazer com o que lhe era ofertado por séculos. Com a revolução tecnológica dos anos 1950 que culminou na internet como a conhecemos atualmente nos anos 1990, observamos uma mudança significativa deste consumidor.

Prahalad e Ramaswamy (2004) descreveram essa mudança no papel do consumidor destacando o seu caráter antagônico: “de isolado para conectado, de desavisado à informado, de passivo para ativo¹”. Howe (2008) denominou esta mudança de renascimento do amadorismo, caracterizado pelo exercício de um papel mais ativo pelo consumidor/indivíduo na sociedade, na qual este utiliza seu tempo livre não só em distrações não-econômicas, mas também, em atividades economicamente produtivas e na criação de conteúdo.

Ao utilizarem *sites* como *Facebook*, *Google*, *Twitter*, os consumidores passaram a gerar um volume significativo de dados que são utilizados, entre outras coisas, para gerar rentabilidade. Este novo perfil de consumidor passou a demandar uma relação bilateral com as empresas e criou novas fronteiras a serem exploradas pelo *marketing*, pelo processo produtivo e administrativo, que se não as acompanhar, perderam seu mercado e serão enfrentam a concorrência acirrada que esta revolução criou.

Neste contexto, Howe (2008) denominou o processo de aproveitamento das capacidades produtivas de consumidores para fins específicos de “*Crowdsourcing*”. Brabham (2008) definiu esse conceito como um novo modelo de negócio baseado na internet, no qual se coleta soluções criativas distribuídas por indivíduos por meio de uma rede de relacionamento disponível a atender questionamentos feitos a elas.

Explorando este conceito de que as empresas que pretendem sobreviver no ambiente digital precisam ser capazes de manter um relacionamento próximo e bilateral com seus consumidores, sendo capazes de interpretá-los, auxiliá-los e assim fidelizá-los, que buscamos um meio onde o capital intelectual das massas possa ser utilizado de forma estratégica na

¹ Tradução livre pelo autor do trecho original em inglês: “(..) from *isolated to connected*, from *unaware to informed*, from *passive to active*”.

construção de relacionamentos e na derivação de capital da interpretação deste conhecimento subjetivo criado por eles.

Para isto focamos o estudo em varejos eletrônicos (*e-commerce*) que utilizam em sua rede uma plataforma de *crowdvoting* sobre os produtos ofertados na rede a partir de um sistema reputacional para analisar o impacto desta estratégia na venda de produtos.

O diferencial deste estudo é a aplicação de técnicas de análise de sentimentos conduzidas através de técnicas de *machine learning* sobre o conteúdo gerado pelos usuários destas redes (*UGC – User Generated Content*) comparando a percepção expressada pelas críticas realizadas as notas objetivas das avaliações (notas de 1 a 5 concedidas pelos usuários) em três empresas norte americanas e posteriormente comparando os efeitos observados desta estratégia em uma empresa brasileira.

Boa parte dos estudos acadêmicos realizados focaram na utilização do índice objetivo ao invés do conteúdo subjetivo dos *reviews* devido a dificuldade de processá-los conforme discorrido por Godes e Mayzlin (2004). Outros trabalhos relativos a análise subjetiva do UGC limitam suas amostras a poucos comentários ou a estudos de casos de uma empresa específica, caminho que optamos por não seguir. Neste estudo selecionamos quatro empresas (três americanas e uma brasileira) e exploramos os efeitos de 94.595 reviews.

Outro ponto divergente deste trabalho é a comparação da aplicação desta estratégia com uma empresa brasileira, os estudos publicados em sua maioria se focam na empresa Amazon, e há poucos estudos de comparação *cross-cultural* deste tipo de aplicação e se limitam a países desenvolvidos (Japão e Canada) e a China.

Observamos nas análises que o comportamento da estratégia atua, ainda que de forças divergentes, de forma análoga em ambos os países, compondo vantagens estratégicas frente ao fortalecimento da marca, no processo decisório do consumidor e consequentemente no desempenho dos produtos.

Também identificamos um descolamento importante da percepção do usuário em suas críticas subjetivas frente a nota objetiva, o que pode acarretar distorções na aplicação das estratégias e ao desgaste do relacionamento entre empresa e cliente por basear suas interpretações em dados imprecisos.

1.1 Problema de Pesquisa

Na literatura atual da administração e marketing é aceito que o boca a boca (*e-WoM – eletronic word of mouth*) exerce influência direta na reputação das corporações e consequentemente no desempenho das vendas de seus produtos/serviços (Barreto, 2014; Chu

& Choi, 2011). O controle e acompanhamento deste processo e o acesso a visão subjetiva da percepção de seus consumidores a partir do conteúdo gerado por estes, bem como a resposta tempestiva a estas inseguranças ao longo do processo decisório do consumidor se torna um diferencial competitivo importante.

Frente a este cenário, as empresas têm buscado estratégias para acompanhar e fidelizar este cliente, e em ambientes de varejo eletrônico a estratégia comumente adotada é a formulação de um canal de diálogo entre consumidores e empresas que visa explorar as vantagens do *e-WoM* dentro do processo de decisão de compra pelo consumidor.

Nós entendemos que este cenário, quando subutilizado, comumente não aproveita todo o potencial econômico que a utilização da estratégia de *crowdvoting* – utilização do *e-WoM*, da análise e interpretação do lado objetivo e subjetivo das críticas realizadas (*UGC*) e a formação de rede sociais dentro de suas estruturas corporativas de venda - pode oferecer. Desta forma a compreensão da extensão desta estratégia e seus impactos no processo decisório do consumidor, na construção da marca e na *performance* de vendas resultantes disso é vital. Adicionalmente visamos colaborar com o avanço da literatura atual na aplicação desta estratégia dentro de ambientes de varejo eletrônico.

A fim de averiguar seus efeitos e sua eficiência, propomos avançar os estudos existentes que se baseiam na mensuração das ações pelo score objetivo das avaliações, e analisamos sob seu ponto de vista subjetivo, através da análise de sentimentos realizadas por máquinas através de inteligência artificial, e assim analisar se as métricas utilizadas nos demais estudos se mantêm constantes, comparando o lado objetivo com o subjetivo, ao explorar o capital econômico latente do segundo (Zhang & Vásques, 2014).

Outro ponto é a falta de estudos mostrando os efeitos em diferentes países, principalmente levando-se em conta o cenário brasileiro. Para explorar esta ausência optamos por explorar a aplicação desta estratégia em comércio eletrônico brasileiro e compará-lo com os efeitos observados no cenário norte americano.

Para este fim, optamos por analisar os efeitos do *crowdvoting* pela triangulação de três empresas norte americanas, para caracterizar um modelo de aplicação, e sua posterior comparação com uma empresa brasileira para que possamos analisar o comportamento de estratégias de *crowdvoting* em países distintos e assim compreender se a sua utilização se mantém benéfica ou não.

1.2 Objetivo Geral

O objetivo central deste estudo é analisar os impactos da estratégia de *crowdvoting* em varejos eletrônicos (*marketplaces*) a partir do entendimento de sua influência na percepção do cliente/usuário sobre o conteúdo gerado por seus pares, seu comportamento frente a diferentes culturas, ao comparar o cenário americano com o brasileiro, e avaliar a eficácia da utilização do *score* objetivo *versus* a percepção subjetiva da gestão do conteúdo gerado pelos usuários (que é parte da interpretação que seus pares utilizam na escolha de produtos) *versus* ao que grande parte dos estudos acadêmicos vem utilizando em suas análises.

Para esta abordagem visa-se explorar o engajamento dos usuários/clientes deste tipo de varejo e os efeitos que propiciar o ambiente aberto a avaliações subjetivas estruturadas em estratégia de avaliação dos produtos/serviços pelo *crowdvoting* acarretam na operação, seja por aumentar a fidelização deste cliente/usuário ou por permitir a coleta de dados relevantes ao posicionamento, processo de compra e estratégia de comunicação/vinculação destes produtos.

Para isto inicialmente busca-se obter o panorama dos efeitos desta estratégia no mercado norte americano a partir da análise de três grandes varejistas e dos resultados encontrados realizar o contraponto com um grande varejista brasileiro para averiguar se as observações caminham na mesma direção em ambos os mercados.

Para direcionar os testes de forma a cobrir os objetivos propostos, formulamos e pretendemos testar as seguintes hipóteses:

- ✓ H1 – *Crowdvoting* aumenta o engajamento e fidelização dos usuários a um varejo eletrônico.

Comércios eletrônicos, como os *marketplaces* avaliados, dependem fortemente de sistemas reputacionais para assegurar sua viabilidade e eficiência, e ainda que a importância destes sistemas seja amplamente reconhecida na literatura (Resnick et al, 2006 & Dellarocas 2003), nestes mercados digitais a reputação é codificada por um perfil reputacional que provê aos seus clientes um histórico de transações efetuadas, avaliações concedidas por seus usuários para transações completadas com sucesso e uma lista cronológica da experiência desses usuários em forma de texto sobre o produto/serviço ofertado.

A maioria destes estudos se limita na avaliação dos *scores* obtidos por estes varejos eletrônicos e não aprofunda na real percepção ou direção da avaliação do usuário. Aliado a esta limitação observa-se que alguns varejos eletrônicos investem mais na estrutura do usuário, propiciando na criação e manutenção de redes sociais, onde existem avaliação de pares frente as avaliações realizadas.

Estudos tem mostrado consistentemente que dentro deste ambiente observa-se um número de avaliações positivas consideravelmente maior que as negativas – ao avaliar a partir do score dado apenas – e que as notas mais altas são comumente descartadas ou não levadas em consideração em mesmo grau que avaliações intermediárias e negativas, porém um outro cenário se forma ao considerarmos as avaliações dos *reviews* postados.

Este engajamento de comunidade, que lê e se alto avalia, de forma indireta cria uma comunidade fidelizada a entidade que gere tal comércio e que mantém a sua frequência, sendo um indicativo interessante quanto a coesão e a formação de comunidades dentro do espaço, apresentando assim uma vantagem competitiva de manutenção deste consumidor e seus pares, já divididos dentro de seus interesses particulares (Bynjolfsson & Smith, 2000, Clay et. Al., 2001, Chevalier & Goolsbee, 2003a, 2003b).

Assim propomos testar o volume de transações realizadas e de avaliações dos comentários realizados dentro de suas comunidades por entidades, ao comparar o volume de caracteres utilizados nos conteúdos gerados nas avaliações.

- ✓ H2 – A percepção subjetiva do consumidor (UGC) não acompanha a direção do rating concedido no score do *Crowdvoting*.

Estudos demonstram que a avaliação dos usuários exerce influência direta no estabelecimento da confiança do consumidor e assim no processo decisório de compra de produtos como livros e filmes em ambientes eletrônicos (Chevalier & Mayzlin, 2006), porém a grande maioria destes estudos se foca no índice obtido pelas avaliações para realizar a análise deste impacto, sem analisar os comentários (ou avaliações) em si, devida a dificuldade desta tarefa, conforme demonstrado em Godes e Mayzlin (2003).

Porém ao não levar em conta as informações mistas ou dissonantes que podem compor estas avaliações, a percepção real sobre a visão da comunidade e dos usuários pode se perder ou apresentar distorções relevantes que poderia levar a crença de que a eficiência ou o relacionamento causal das avaliações não está sendo claramente refletida nos movimentos de vendas (Chevalier & Mayzlin, 2003)

Adicionalmente, a literatura enfatiza que os efeitos do “boca-a-boca” (*Word of Mouth*) apresentam um peso consideravelmente maior na percepção do consumidor, quando abordam os aspectos negativos do produto (Fiske, 1980; Skowronski, & Carlston, 1989).

Assim, uma visão distorcida da real percepção do usuário pode representar a perda de oportunidades de melhorias e ações pontuais que reativem a performance de produtos ou serviços em momentos de lançamento – onde o boca-a-boca apresenta maior influência (Geng Cui, Hon-Kwong Lui & Xiaoning Guo, 2012).

Para isto busca-se testar se a pontuação concedida pelos usuários (*Review Score*) reflete o mesmo sentido da argumentação apresentada em suas avaliações (*Review Content – User Generated Content*), as quais serão a base de construção ou desconstrução da segurança dos consumidores/usuários da plataforma.

- ✓ H3 – Em ambientes globalizados os efeitos do *crowdvoting* se mantêm independentemente da localização geográfica de seus consumidores (comparativo USA x BR).

Estudos relevantes vem se aprofundando nas diferentes percepções sobre o boca-a-boca digital (*e-Word of Mouth*) causadas por diferenças culturais. Pesquisadores analisaram a percepção e as diferenças na frequência, percepção e impacto nas vendas dos produtos em países como Japão e Estados Unidos (Hsin-Chen Lin & Manohar U. Kalwani, 2018) e China e Canada (Geng Cui, Tsang-sing Chan & Annamma Joy, 2008); porém até o momento não é de nosso conhecimento comparativos que efetuem a análise dos conteúdos gerados por usuários e a análise de sentimentos por Inteligência Artificial (IA) em comparativos de mercados de países desenvolvidos (como Estados Unidos) e o Brasil.

Desta forma, a fim de analisar o comportamento do consumidor brasileiro e o impacto do boca-a-boca digital dentro de nossa realidade frente aos comportamentos observados nas empresas norte americanas, optou-se por testar a hipótese H3.

1.3 Justificativa

Como resultado da globalização da economia, ocorreu significativa intensificação na competição entre as empresas em todos os mercados, obrigando-as a se adaptarem de forma cada vez mais rápida aos mercados, acelerando seu ciclo de inovação e otimizando os seus custos de operação a fim de poderem sobreviver neste novo ambiente econômico. Soma-se a isso, a ocorrência de diversas crises financeiras ao redor do mundo, ao exemplo da crise financeira de 2008 que aumenta as incertezas e disputas econômicas.

Nesse cenário, a importância do fortalecimento de sua marca e um relacionamento próximo com seus consumidores se torna vital. A literatura do marketing trata da importância do boca-a-boca na construção da marca e no sucesso das vendas de produtos/serviços em mercados competitivos (Chu & Choi, 2011; Baird & Parasnis, 2011).

Com o aprimoramento da internet e o amplo acesso as redes sociais, o boca-a-boca caminhou para o mundo digital ampliando seu alcance e a velocidade de suas interações,

propiciando uma nova realidade em que as empresas podem monitorar e interagir de forma mais efetiva com seus consumidores, bem como compreender melhor o ponto de vista destes ao acompanhar e analisar suas críticas a partir do conteúdo publicado por estes (Shirky, 2008).

A fim de atuar sobre o conteúdo gerado por usuários (*UGC*) e acompanhar este boca-a-boca da era digital (*e-WoM*), as empresas estruturaram diversas estratégias, entre elas a disponibilização de canais para fomentar redes sociais dentro de seus varejos eletrônicos (*e-commerce*) onde incentivam e monitoram o comportamento de seus consumidores e suas percepções.

Uma destas estratégias é a disponibilização de uma rede focada na avaliação e no compartilhamento de críticas e opiniões sobre os produtos/serviços ofertados, que se baseia na concessão de uma pontuação objetiva e de dados subjetivos que suportam esta nota gerados de forma espontânea pelos participantes destas redes (consumidores do serviço). A esta estrutura Howe (2008) chamou de *Crowdvoting*, contando assim com o conhecimento e a sabedoria das massas que avaliariam e opinariam sobre os produtos/serviços ofertados.

Desta forma entende-se que compreender a estrutura de *Crowdvoting* e a sua aplicação em ambientes de varejo eletrônico apresenta um importante diferencial competitivo por explorar os benefícios do *e-WoM* e do *UGC* a fim de alavancar a performance dos produtos/serviços ofertados (em consonância com a literatura existente, porém com a atualização dos conteúdos para o ambiente digital).

Outro ponto relevante é que há diversos estudos sobre o impacto do *e-WoM* na *performance* de vendas, porém a grande maioria foca na relação objetiva das notas concedidas e utilizam bases reduzidas a fim de averiguar o fenômeno em questão.

Nesta pesquisa é proposta utilizar base de dados mais amplas a fim de explorar um volume de dados que reflita as grandes massas trabalhadas por estas entidades e, através de técnicas de *machine learning* e inteligência artificial, realizar a análise de sentimento dos textos subjetivos a fim de analisar se a opinião dos usuários de fato é refletida nas notas concedidas, por entender que a real mensagem contida neste conteúdo gerado apresenta grande valor econômico para as entidades (Zhang & Vásques, 2014).

Outro ponto observado nas pesquisas existentes é que o foco das análises são empresas norte americanas ou a relação de empresas em países desenvolvidos e/ou com amplo acesso à *internet* (tais como Japão e China), porém não é de nosso conhecimento a comparação desta

estratégia em varejos eletrônicos nacionais, sendo parte da proposta deste trabalho a análise da estratégia de *crowdvoting* no Brasil e seu comparativo frente a empresas Americanas.

2 REFERENCIAL TEÓRICO

Este capítulo está estruturado de forma a apresentar os conceitos que sustentam a aplicação de estratégia de *crowdvoting* em comércios eletrônicos. Para isto propomos a revisão da literatura atual e sua conexão com o objeto de estudo deste trabalho, a apresentando como pilares de sustentação divididos em sessões de acordo com o tópico apresentado.

A fim de colaborar com o entendimento do leitor e manter uma estrutura didática, dividimos estes pilares em: Consumidor – Comportamento e Processo decisório, Marcas – Construção de Marcas e comunicação integrada de marketing, Colaboração - Inteligência coletiva e *Crowdsourcing* e por último a composição do *Crowdvoting* – *Word of Mouth*, *User Generated Content*, Sistemas Reputacionais e *Crowdvoting*.

Cada pilar visa atingir um objetivo específico, conforme pontuado abaixo:


- ✓ Consumidor: pontuar quem é o consumidor e como este reage frente a estrutura de *crowdvoting* e como esta afeta o seu processo decisório no momento de compra,
- ✓ Marcas: Definir o conceito de marca, como esta é construída e se comunica com seu público alvo a fim de relacionar as ações de comunicação e de relacionamento com seu público as estratégias de *crowdvoting* analisadas.
- ✓ Colaboração: Definir os conceitos de inteligência coletiva, potencial econômico e vantagens competitivas de seu uso e apresentar os conceitos de *crowdsourcing* e suas aplicações atuais.
- ✓ *Crowdvoting*: Apresentar o conceito de *crowdvoting* com profundidade, separando suas estruturas de funcionamento e explicar seus constructos *e-WoM*, *UGC* e Sistemas Reputacionais.

2.1 Comportamento do Consumidor

O comportamento do consumidor é uma área de estudo da administração que segundo Solomon (2011), o campo onde o estudo dos processos envolvidos quando indivíduos ou grupos destes selecionam, compram, usam ou dispõem de produtos, serviços, ideias e experiências para satisfazer suas necessidades e desejos ou a partir de outros autores temos que o comportamento do consumidor diz respeito às atividades com que as pessoas se ocupam quando adquirem, consomem e desfrutam de produtos/serviços (Blackwell, Miniard & Engel, 2005).

De forma simples podemos definir o comportamento do consumidor como a elucidação das razões que motivam uma pessoa a comprar e consumir um produto/serviço em detrimento de outro. Desta forma é razoável aceitarmos que este comportamento varia de pessoa para pessoa e que é influenciado por sua renda, idade, instrução, cultura, gostos, localização geográfica (Solomon, 2011; Schiffman & Kanuk, 2000).

Dentro deste comportamento alguns autores, como Gioia (2006) necessita de informações derivadas de quatro áreas específicas, sendo estas: características demográficas do consumidor, comportamentos de consumo, atitudes e processo de compra. Seguindo esta lógica Kotler e Armstrong (2007) propuseram um modelo sobre o comportamento do consumidor, dividido em 3 blocos (Figura 1):



Fonte: Kotler & Armstrong, 2007.

A partir deste modelo podemos observar que a parte do consumidor, denominada caixa-preta do consumidor detém o processo decisório realizado por ele e as suas características individuais, as quais não transparecem de forma clara a terceiros e carregam muita subjetividade e percepções próprias que detém um valor econômico relevante, mas de difícil acesso.

Seguindo o fluxo proposto por Kotler e Armstrong observamos que os estímulos controlados pelas estratégias de marketing (preço, produto, canais e comunicação), juntamente

com outros estímulos externos (fatores econômicos, públicos e culturais) são percebidos pelo consumidor que processará esses dados de forma consciente e inconsciente a fim de gerar as respostas do comprador na escolha da marca, do produto, do revendedor, do volume e frequência de compras.

Entre diversos outros fatores, um fator relevante de influência ao consumidor são grupos a que ele pertence ou participa. Conforme Karsaklian (2000), o consumidor recebe influências de grupos primários e secundários, onde os primeiros representam seus laços afetivos íntimos e pessoais enquanto os secundários são caracterizados por relações formais e impessoais. Corroborando com esta visão Kotler (2007) complementa que este também sofre influência por outras associações, formadas por grupos de referência que agem como pontos de comparação direta ou indireta para este consumidor.

Aprofundando este um ponto, uma vez que parte dos efeitos de se adotar uma estratégia de *crowdvoting* é a formação de uma comunidade e/ou grupo de indivíduos que se manifesta e partilha sua visão crítica frente a produtos/serviços ofertados, recuperamos Gade (1980) e Solomon (2011) que reforçam que os grupos de referência são compostos por um indivíduo ou grupo, real ou imaginário (tomamos a liberdade de pontuar como virtual em interpretação própria), concebido para dar relevância significativa às avaliações, aspirações ao comportamento do indivíduo.

Os autores pontuam que estas influências podem ocorrer de três formas distintas:

Informativa: O consumidor busca, observa e seleciona informações sobre várias marcas em associações ou grupos independentes de especialistas;

Utilitária: O consumidor tem sua decisão influenciada pelas preferências daqueles com quem interage socialmente;

Expressiva de valor: Relaciona-se as crenças deste consumidor quanto à compra e o uso da marca que anseia em possuir.

Adicionalmente Kotler e Armstrong (2007) pontuam que não raramente, as pessoas são influenciadas por grupos aos quais não pertencem, por grupos que submetem as pessoas a novos comportamentos e estilos de vidas, influenciam suas atitudes pessoais e sua autoimagem por intermédio de pressões de adaptação que acabam por afetar suas escolhas em relações a marcas e produtos, e que esta influência apresenta um maior impacto quando o produto é visível para pessoas que o comprador respeita.

Complementando esta visão, e caminhando em direção do espaço a que este trabalho se situa, exploramos um pouco do comportamento deste consumidor dentro do ambiente virtual,

pela evolução dos hábitos de consumo e as distorções que isso acarretou o comportamento observado anteriormente, ao conceder um maior poder de escolha a este consumidor.

Este consumidor passa a ser definido por Santos (2016) como conectado, produtor, ubíquo e globalizado, fazendo parte de uma geração singular que apresenta suas tendências comportamentais resultantes da disponibilidade tecnológica a qual ela tem acesso. Possui forte presença digital e intimidade com a tecnologia. Uma geração que sabe o que quer e quando quer, e desta forma, exige um esforço concentrado e bem planejado para conseguir atender suas demandas e proporcionar o engajamento com a marca.

Com esta visão deste novo consumidor, vemos a formação de uma geração acostumada com tecnologia, rodeada por conteúdos interativos, autônoma, que realiza troca e compartilha conteúdos na internet como sua casa, demandando a interatividade como dever e não aceitando formas de intromissão agressivas e unidirecionais (Marketing Future Cast Lab, 2012).

Esse consumidor é descrito por Lévy (1996) ao mencionar o usuário que busca interagir com a informação, rejeitando os meios de mídia clássicos, acompanhando o aumento da *performance* das redes que encurtam as distâncias geográficas até torná-las insignificantes, que nos levaria a um novo e abrangente processo de ‘desterritorialização’.

Este processo caminha para a formação as inteligências coletivas (Lévy, 1998) as quais constituirão parte importante do valor originado pelas estratégias de *crowdsourcing* e de *crowdvoting* aqui analisada.

2.2 Marcas e sua construção

Os autores Keller e Machado (2006) pontuam a origem do termo *brand* (marca) como um derivativo do idioma nórdico que expressa a ideia de queimar ou marcar de forma definitiva algo, expressando assim que a marca é algo que registra o significado e o nome de um produto para um mercado-alvo. Complementando esta definição Serralvo (2006, p.109) pontua que a “marca é o conjunto de referenciais físicos e simbólicos capazes de influenciar e determinar a preferência para os produtos, tendo por base a oferta de valor a ela associada”.

Propõe-se neste tópico apenas situar os pontos principais da construção da marca a fim de posicionar o leitor quanto a importância da construção de credibilidade e do relacionamento desta junto a seus consumidores, explorando assim a dois elementos do sistema percorrido por Kapferer (2004), na busca de compor um significado exclusivo e positivo frente ao maior número possível de consumidores, frente que a marca acabará por interligar as impressões e

experiências, sejam elas negativas ou positivas, que os consumidores formarão ao longo do tempo.

Segundo Kapferer (2004, p.14),

“Um sistema vivo composto de três elementos: um multissinal (nome, identidade gráfica, símbolo), associado a um (ou mais) produto(s)/serviço(s), ao(s) qual(is) é associada uma promessa de qualidade, segurança e pertinência a um universo.”

Ainda seguindo esta linha, recuperamos White (2004) que discorre sobre a marca como um meio pelo qual empresas exercem diferenciações a fim de proteger a sua posição no mercado ao longo do ano, destacando a importância da construção de relacionamento com seus consumidores para que a marca se mantenha viva na mente deles, complementando o sistema de Kapferer (2004) que reforçam desta forma em conjunto a importância da construção de confiança e do relacionamento constante das marcas com seus consumidores.


Para White (2004, p.77),

Uma marca é o meio pelo qual uma empresa diferencia seus produtos dos concorrentes e – se bem-sucedida – protege sua posição no mercado, de maneira lucrativa, ao longo dos anos. Para que isso ocorra, a marca tem de construir um relacionamento com seus consumidores; se a marca não estiver de algum modo “na mente” de seu mercado-alvo, poderá, na melhor das hipóteses, representar apenas uma compra aleatória.

Desta forma seguindo a construção de uma marca e identidade há entre outros, quatro fatores importantes a serem considerados segundo Keller (2013), sendo estes:

1. identidade da marca frente aos seus consumidores, em suas mentes, da marca com uma categoria de produtos ou com as necessidades de clientes;
2. o significado da marca na mente, fazendo uma assimilação tangível e intangível da marca;
3. verificar as respostas dos consumidores à identidade e ao significado da marca;
4. fidelização e lealdade à marca num relacionamento obtido com os cliente-alvo.

Em consonância a esta visão diversos autores propõem modelos já aceitos e discutidos na literatura quanto a modelos de construção de marca, tais quais Aaker e Joachimsthaler (2007) e Keller (2013). Dado o recorte teórico deste estudo, e a fundamentação de partes do constructo das marcas que podem ser suportados pelas estratégias de *crowdvoting* analisadas, optamos por exemplificar pelo modelo de pirâmide de valor de marca baseada em consumidores de Keller (2013).

Figura 2: Pirâmide de valor de marca

Fonte: Keller, 2013.

Em seu modelo Keller (Figura 2) distribuí em quatro etapas, observadas da base da pirâmide com direção ao seu topo, onde ele aborda a questão da (1) identidade da marca, o seu (2) significado, o que ela (3) comunica e os (4) relacionamentos que são constituídos por ela.

Optamos por utilizar este modelo pela visualização de frentes que podem ser trabalhadas de forma complementar pela estratégia de *crowdvoting* e que serão exploradas adiante na análise deste trabalho.

Ainda que o foco seja na atuação desta estratégia em comércios eletrônicos, que praticam a venda de produtos de diversas marcas, o próprio varejo constrói a sua marca sobre o serviço ofertado (venda de produtos/serviços pela internet) e de forma secundária propicia dados para a gestão e aperfeiçoamento destas marcas vendidas em seu espaço.

Isto se dá primeiramente pelo conteúdo gerado pelos usuários de forma espontânea (*UGC*) e pela análise do conteúdo subjetivo resultante das críticas e discussões destas entre si (*e-WoM*), em acordo com as etapas três e quatro do modelo de construção de Keller, que reforçam a importância da comunicação e manutenção do relacionamento junto ao mercado consumidor.

Outro ponto é que esta estratégia, quando adotada, resulta na formação de uma rede de usuários, frequentadores/utilizadores deste ambiente que formam uma rede social de consumidores, que deve ser acompanhada e trabalhada conforme a colocação de White (2004), para a manutenção deste relacionamento e para o complemento da segurança percebida pelos

outros consumidores frente aos produtos ofertados, tópico a ser abordado com maior profundidade no tópico relativo ao *e-WoM*.

2.3 Comunicação integrada de marketing

Já é bem estabelecido pela literatura, e de comum acordo entre diversos autores, a importância de uma comunicação integrada de marketing em relações interdisciplinares da marca com o consumidor atualmente (Kotler, 2000; Kotler & Keller, 2012; Aaker & Joachimsthaler, 2007; Galindo, 2008; Semprini, 2006).

De acordo com Shultz e Barnes (2006) a comunicação da marca deve ser realizada de forma integrada e cabal, da perspectiva do cliente, as quais os autores dividem em 6 fatores, sendo estes:

- ✓ Promoção de Vendas
- ✓ Publicidade
- ✓ Eventos
- ✓ Patrocínio Corporativo
- ✓ Relações Públicas
- ✓ Marketing Direto

Estes fatores, em conjunto atendem ao cliente e corroboram para a determinação de um significado de mercado que resulta na comunicação integrada. Ainda nesta estratégia, por sua definição de comunicação de marcas ressaltamos a citação a seguir:

A comunicação é tudo aquilo que ajude a transmitir significado de uma pessoa à outra, de um produto ou serviço ao consumidor. Dessa maneira, a comunicação pode ser a forma, o valor ou a qualidade de um produto ou serviço. Pode incluir informações, sobre o local em que o produto ou serviço esteja disponível, a embalagem, o preço, quer sugerido no momento, quer em comparação a outros produtos ou serviços concorrentes.

A maneira de se fazer a comunicação da marca também pode incluir vários usuários ou consumidores atuais da marca, que os novos usuários possam ver ou ouvir falar e querer, consequentemente imitar. Em outras palavras, a comunicação da marca é o pacote total de benefícios, valores, ingredientes, formas físicas, mensagens formais ou informais, e tudo o mais que em conjunto, confira significado e benefício ao cliente atual e prospectivo. Comunicação é toda a forma pela qual a marca e sua essência toquem o cliente atual ou prospectivo. (Schultz & Barnes, 2006, p.44).

Assim, as organizações necessitam criar conexões diretas com seus consumidores, medindo as influências determinantes de cada canal de comunicação integrada de marketing frente ao comportamento do consumidor atingido por esta comunicação. Segundo Shimp

(2002), isto deve ser feito de forma a afetar o comportamento do cliente, começar com o cliente ou prospecto, usar toda e qualquer forma de contato, gerando sinergia e construindo relacionamentos.

Deste trecho reforçamos que a comunicação de marca pode incluir vários usuários ou consumidores que possam influenciar novos usuários e a disseminação de informações sobre o produto, preço e locais em que se encontram e sua qualidade (Schultz & Barnes, 2006) e o posicionamento de Shimp (2002), que destacam pontos que confluem para benefícios propostos para a estratégia estudada neste trabalho e se compõem como constructos importantes do *crowdvoting* e seu efeito na performance dos produtos ofertados pelos varejos eletrônicos.

2.4 Processo decisório do consumidor

Todo o processo percorrido pelo consumidor para se decidir e efetuar a compra e o consumo de um bem é chamado de processo de tomada de decisão e entre diversas informações necessita de dados processados na mente de seus consumidores que podem ser originados internamente (sua memória) ou externamente, levantando a uma decisão que em muitos casos não é tomada por um único indivíduo.


A fim de ilustrar o processo a fim de compreendemos as partes deste processo onde observamos pontos de intersecção que podem ser explorados e trabalhados pela estratégia em estudo neste trabalho, opta-se por expor uma das teorias mais utilizadas por pesquisadores da área, sem a finalidade de esgotar o tema, mas para posicionar o leitor das nuances desta aplicação.

Escolhe-se por trabalhar com o modelo do processo decisório (Figura 3) proposto por Blackwell (2013), que expõe as etapas do processo decisório e discute, frente a outros autores como Mowen e Minor (2003), etapas adicionais após a escolha de compra e expõe alguns componentes subjetivos, que se alinham com benefícios derivados da estrutura de *crowdvoting*, aqui discutida.

Blackwell (2013) tece sua teoria a partir do reconhecimento da necessidade, este sendo o fruto da identificação, por parte do consumidor, sobre a sua situação atual e a desejada. Essa identificação é discutida como indo além a relação entre a satisfação da necessidade que o produto proporciona e seu custo, sendo que essa satisfação deve ser maior que o custo para a tomada de decisão.

O autor também considera as necessidades de seu consumidor como possíveis desejos que podem enveredar as decisões de alguns consumidores durante seu processo examinatório.

Figura 3: Processo decisório de Compra



Fonte: Blackwell, 2013, p.86

Observa-se assim que partindo da identificação da necessidade, em paralelo a busca interna temos uma busca externa sujeita a influências ambientais, entre elas influências de pessoais, culturais, situacionais e de família, que ocorrem no momento de pré-compra e são complementadas pela memória deste indivíduo que é alimentada, entre outras coisas por opiniões de profissional não mercadológico.

Posteriormente a compra, Blackwell ainda retoma as etapas pós consumo, na avaliação da insatisfação ou satisfação deste produto, que pode retroalimentar a etapa de pré-compra, ou a comunicação desta insatisfação externamente pela geração de sua opinião e divulgação de estímulos (como profissional não mercadológico) a outros consumidores (Chu & Kim, 2011; Lin et al., 2014).

A partir da memória, Blackwell et al. (2013) aponta que ela ativada na busca interna por informações ao recuperar o conhecimento pré-existente e ao realizar a busca externa, ativada pela atenção, compreensão e aceitação, os quais precedem a exposição gerada por um estímulo proposital.

Seguindo assim para a pré-compra, com o afinamento de opções para posterior compra por intermédio de comparação e seleção entre os produtos e marcas disponíveis. Neste ponto a memória é acessada novamente para facilitar a comparação e prever a possibilidade e satisfação

por experiências anteriores, sobre produtos equivalentes ou por histórias de pessoas conhecidas que compraram os produtos.

No estágio de compra temos duas etapas distintas, onde a primeira diz respeito a escolha do tipo da venda (seu canal) e a segunda ser dá pelas escolhas do que será adquirido dentro deste canal. Aqui a intenção de compra por parte do consumidor já se encontra formulada, e que ainda assim, viabiliza a compra de algo que não o satisfaça – sendo o produto adquirido algo diferente do inicialmente proposto por si mesmo.

Blackwell et al. (2013) também segrega a compra do consumo afim de destacar que o consumo pode não ocorrer de forma imediata, e este consumo, dependendo de quando for realizado por influenciar a *performance* do produto adquirido, e consequentemente a satisfação deste comprador, que será manifestada na fase de pós consumo. Ainda aqui o autor trabalha com a possibilidade de descarte que se traduz na revenda ou destruição do item.

O autor em seu trabalho ainda discute com maior profundidade outros fatores que influenciam o processo de decisão, como demografia, valores, recursos do consumidor, motivação, conhecimento, memórias, atitudes e a avaliação formada sobre os produtos.

Outros autores como Nicosia (1966) e Mowen Minor (2003), discutem o modelo do processo decisório, com suas particularidades, mas sem prejuízo para a compreensão dos pontos em que a estratégia discutida pode influenciar dentro deste processo.

Ressaltamos assim, sobre o modelo de Blackwell et al. (2013), que há pontos de atuação na utilização de *crowdvoting* pelos varejos eletrônicos (e-commerce) nas etapas de pré-compra, pós-consumo, influências ambientais, busca externa e estímulos de profissionais não mercadológicos.

Na pré-compra observa-se o impacto exercido pelo *e-WoM* a partir do conteúdo gerado pelos usuários desta plataforma; que estão em sua maioria no momento de pós-consumo; que colaboram para aumentar a segurança do consumidor e tendem a influenciá-lo, com maior credibilidade do que informações recebidas por estímulos profissionais estruturados, tais quais propagandas.

No pós-consumo vemos o *crowdvoting* propiciar um canal para a expressão da opinião deste consumidor, realimentando o fluxo e atuando como um profissional não mercadológico que suprirá a busca externa de um próximo interessado e agirá em paralelo como uma influência ambiental a este comprador (Kucukemiroglu & Kara, 2015).

2.5 WoM (*Word of mouth*) e e-WoM

A partir da literatura do marketing, o “boca-a-boca” ou *Word of Mouth*, pode ser entendido como a forma de realizar a troca de informações - ou diálogo direto - sobre produtos e serviços entre consumidores (Chu & Kim, 2011; Lin et al., 2014), porque até então isto era realizado presencialmente entre dois consumidores.

É um método de comunicação informal e ocorre através de um canal interpessoal entre duas partes, ou atores, que podem ser vizinhos, amigos ou familiares que expressam suas opiniões para outros atores, entre estes potenciais consumidores dos produtos discutidos.

Desta interação observa-se o *Word of Mouth* (WoM) que retrata o resultado da satisfação ou insatisfação do consumidor frente ao produto/serviço consumido, e que de acordo com este grau de satisfação percebido maior será a satisfação frente a entidade que o proveu, colaborando para a construção de uma boa marca e a fidelização deste consumidor (Wallace et al., 2014); enquanto que em caso de insatisfação este WoM ser provará destrutivo, visto que o impacto de percepções negativas é consideravelmente superior ao efeito positivo causado pela satisfação no usufruto do bem/serviço (Christodoulides et al, 2012; Grégoire et al, 2014).

Diversos estudos retratam a importância de acompanhar e tratar o WoM pelo fato de que os consumidores/usuários depositam ampla fé nesta informação, ultrapassando a credibilidade e confiabilidade de informações distribuídas através de campanhas publicitárias ou por vendedores (Edelman, 2010).

Através da revolução da internet e o surgimento das mídias sociais, obteve-se um canal pelo qual os usuários pudessem criar engajamento e funcionar online de formas distintas e assim manter contato com seus amigos, ter acesso a fatos e eventos mundiais e realizar a troca de informações sobre empresas e produtos de forma mais efetiva, o que culminou na evolução do WoM para o chamado e-WoM (Huang et al., 2011; Cheung & Thadani, 2012), o boca-a-boca aperfeiçoado pela internet e por esta evolução nos canais de comunicação e de ligações de redes.

Este fenômeno acaba por suportar grande parte do incentivo a aplicação de estratégias, websites e aplicativos que permitam que os usuários gerem conteúdo e publiquem suas opiniões sobre produtos e serviços, e tem se mostrado crucial dentro das estratégias de marketing e de vinculações de produtos – alinhados desta forma ao foco deste estudo – pelo grau de credibilidade desta informação (Kucukemiroglu & Kara, 2015) e pelo viabilidade do canal eletrônico da internet que permite que possa-se captar e gerenciar esta informação de forma barata e rápida.

A partir desta plataforma observa-se o *e-WoM* ocorrendo em canais de comunicação entre indivíduos/usuários que se comunicam pelos sites através de aplicações para manifestar a sua opinião no mundo digital. Barreto (2014) e Chu and Choi (2011) descrevem *e-WoM* como qualquer declaração positiva ou negativa feita por potencial, atual ou antigo consumidor sobre um produto ou empresa, que é disponibilizado para uma multidão de pessoas e instituições pela internet.

Outro ponto desta evolução de *WoM* para *e-WoM* é a velocidade e o alcance de seus efeito em relação à anterior (Barreto, 2014), a qual disponibiliza sua informação para pessoas que vivem em partes remotas do mundo e está disponível e acessível em um instante para terem suas opiniões observadas e compartilhadas por outros da mesma forma (Phelps et al., 2004).

Complementando a pesquisa presente neste trabalho, o efeito do *e-WoM* no processo decisório de compra e como esta informação é apresentada aos usuários do varejo eletrônico, neste caso sendo analisado dentro da estratégia de *crowdvoting*, é importante e suportado por estudos anteriores que apresentam impacto significativo do *e-WoM* na construção da confiança e no processo de avaliação e estudo de pré compra de um bem/serviço por um consumidor (Chu & Choi, 2011; Baird & Parasnis, 2011; Erkan & Evans, 2016).

Outro estudo realizado por Purgat (2018) evidência que a comunicação em redes sociais em ambientes digitais apresenta um maior efeito do *e-WoM* no estágio de pré compra dentro do comportamento do consumidor, frente ao estágio posterior de compra, no qual o consumidor retorna após o consumo ou obtenção do bem/serviço para avisar a outros consumidores sobre a *performance* deste (See-to & Ho, 2014; Wang et al., 2016). Ambos os estágios (pré compra e pós compra) são trabalhados pela estratégia de *crowdvoting* aplicada pelos varejos observados neste estudo e contém informações pertinentes na captação, retenção e inclinação a compras de seus produtos/serviços por seus usuários.

Ao propiciar um ambiente dentro do espaço de suas barreiras virtuais (um comércio eletrônico que propicia um ambiente de avaliação e livre comunicação – estratégia de *crowdvoting* sobre produtos, no caso deste trabalho) cria-se um ambiente controlado onde é possível acompanhar o conteúdo gerado pelos usuários e desta forma ser um participante ativo do processo de *e-WoM*, a fim de ser capaz de tomar ações preditivas e corretivas para alinhar a plataforma a *performance* desejada de seus produtos. Isto fica alinhado a estudos que atestam que o impacto de *reviews* publicados em ambientes online tem impacto no dispêndio de recursos por parte dos consumidores (Jansen, 2009; Ghose & Ipeirotis, 2011).

2.6 *User generated content*

Posicionamentos estratégicos em cenários competitivos demandam das empresas um conhecimento amplo sobre a perspectiva de seu mercado consumidor, conhecer a fundo os anseios e inseguranças deste consumidor permite que estas possam ampliar sua capacidade de criação de valor, propiciando um espaço de comunicação direta com seu cliente, e muitas vezes entre estes clientes, para que isto seja visto como parte integrante e benéfica do serviço ofertado por estas entidades.

Dentro do ambiente web, onde a movimentação dos clientes entre diversos ambientes de varejo eletrônico é facilitada pela facilidade na consulta de melhores condições de negócio (ainda mais se o foco for a capacidade de consulta e pesquisa de preços) exige que, para que possa manter a sua posição menos suscetível as ameaças do mercado, esta seja capaz de se colocar sob a perspectiva do cliente para avaliar seus produtos/serviços e ofertar um conjunto de recursos que permita fortalecer seu vínculo com este (Shostack, 1984).

A partir desta dinâmica podemos encarar o conteúdo gerado por usuário (CGU) como o meio fornecido pelo seu consumidor (considerações à ambiente web) para representar a sua percepção de forma direta, expressando sua concepção individual e compartilhada sobre o serviço/produto ofertado naquele instante.

Pela Organização para a cooperação econômica e desenvolvimento – OECD, ainda que não haja uma definição amplamente aceita para o termo e para sua medição social, cultural e impacto econômico, UGC (*User-created Content*) ou conteúdo criado por usuário pode ser compreendido como um conteúdo tornado disponível publicamente pela internet que reflete uma certa quantidade de esforço criativo e que é criado além das rotinas e práticas profissionais.

Ainda segundo Shirky (2008), podemos considerar um UGC quando estes criam e compartilham mídia espontaneamente, sem intervenção ou influência profissional, em concordância com George (2007) e Kaplan e Haenlein (2010).

Estes conteúdos gerados por usuários se encontram em diversos formatos como fotografias, vídeos, artigos, *blogs* e neste estudo em avaliações publicadas para os produtos/serviços dos varejos eletrônicos observados, e permitem que seus usuários expressem sua criatividade e registro seus comentários sobre qualquer produto ofertado.

Um ponto relevante é distinguir o conteúdo gerado por usuários de conteúdos trabalhados e preparados por provedores de conteúdo (não simples usuários de internet), tais quais autoridades estabelecidas, *experts* ou um corpo reputacional (P. Chin, 2006). Estes conteúdos preparados geralmente apresentam um maior cuidado na supervisão e controle de

qualidade da informação apresentada que tende a ser vista como mais confiável e crédula, reduzindo o viés do autor.

Há várias formas de se aplicar este conteúdo e de como e porque os usuários geram conteúdo, tais como (George, 2007):

- ✓ Propaganda – anúncios realizados por usuários em plataformas online – ex. Mercado Livre.
- ✓ Análises e comentários – blogueiros que fornecem suas análises, opiniões e comentários sobre diversos assuntos.
- ✓ Contribuir para o conhecimento humano – usuários que editam e complementam artigos em plataformas como a Wikipedia.
- ✓ Críticas e Análises – usuários que manifestam contribuições voluntárias para análises de livros (ex. *Amazon reviews*), produtos (ex. opiniões de usuários) e serviços (ex. comentário de viajantes sobre hotéis no TripAdvisor).
- ✓ Entretenimento – usuários que postam vídeos e conteúdo focado a entreter outros usuários (ex. *Youtube*, *Vimeo*).
- ✓ Educação – ofertar conteúdo educação e de suporte a outros usuários (ex. fóruns que fornecem conselhos e auxílio como *Github*).
- ✓ Intenções maliciosas – Alguns conteúdos gerados por usuários podem ser nocivos e publicados com intenções maliciosas com a finalidade de prejudicar outros usuários (ex. *Malware* e *Adwares* publicados na internet).
- ✓ Notícias e reportagens – publicações feitas sobre notícias amadores, filmagens de transeuntes que podem ou não ser exibidas nas mídias de principal circulação devido as diretrizes de imprensa.
- ✓ Protestos – protestos contra guerras, posicionamentos políticos entre outros.
- ✓ Redes sociais – Compartilhamento de usuários entre si para sua rede de contato e ampliação de círculos de comunicação (ex. *Facebook*).

Dentro destas possibilidades, esta pesquisa foca no conteúdo gerado pelos usuários comuns da internet, que utilizam os ambientes providos pelos varejos para manifestar suas opiniões a partir de críticas e análises, de forma voluntária, online dentro dos ambientes de varejos eletrônicos.

Isto se torna relevante em avaliar os impactos de estratégias de *crowdvoting*, que por sua estrutura acabam por propiciar um ambiente favorável ao *UGC*, pois já foi evidenciado na literatura que a percepção de outros usuários frente a credibilidade destas avaliações é maior do que a de especialistas ou de mídia preparada pelos provedores de serviço (Akehurst, 2009).

Outros autores também observaram este fenômeno e apontaram que a direção da influência dessas avaliações, não contradiz ou anula a de mídias preparadas ou de opiniões de especialistas, porém apresentam diferentes intensidades e que podem ser utilizadas de forma estratégica para ampliar ou reduzir a segurança de consumidor dentro destas plataformas (Lobato, Thomas e Hunter, 2011).

Ainda como diferencial estratégico, mesmo que o uso de testemunhos de clientes é há tempos uma estratégia usual para promoção de marcas, o estudo de Sigala (2012) corrobora o lado estratégico de se incentivar e manter um ambiente propício ao UGC, uma vez que estas interações entre clientes e empresas e clientes e clientes, resulta em emoções positivas que fortalecem a marca e a percepção positiva dos consumidores frente aquela empresa.

Uma vez estabelecido esta relação e a importância na construção deste ambiente para propiciar o relacionamento positivo ainda destacamos o estudo de Zhang e Vásques (2014) que evidenciam que as avaliações dos clientes contem diferenciais econômicos importantes em sua subjetividade e que o tipo de resposta apresentado a estas críticas impactam a percepção da comunidade e de todos os terceiros que monitoram este diálogo entre cliente/empresa através do ambiente digital (Heyes & Kapur, 2012).

Outro ponto importante apontado é que 60% dos consumidores que manifestam suas opiniões neste ambiente esperam uma resposta ou interação quando descontentes (Van Noort & Willemsen, 2011) e que a percepção do contentamento ou descontentamento deste cliente se torna chave, sendo este mais um ponto explorado neste estudo ao validar a eficácia de utilizar apenas o *score* dado ao produto e desconsiderar o conteúdo da mensagem do comentário/crítica.

A reputação do ambiente em que esta informação é postada e informações relativas ao autor da informação também se mostram relevantes e mostram outra faceta importante a ser trabalhada dentro dos ambientes propostos pelo *crowdvoting* provido pelos varejos eletrônicos. A credibilidade destes *sites* e sua reputação foram alvo de estudo de Filieri, Alguezaui e Mcleay (2015), salientando que a percepção deste ambiente também exerce influência direta na intenção dos clientes em seguir as recomendações postadas ou em se engajar no diálogo apresentado.

Caminhando neste sentido observa-se a mesma percepção em comércios eletrônicos pelo estudo de Agag e El-Masry (2017), ainda que focados no ramo de turismo, expressam o mesmo dinamismo de varejos eletrônicos e a necessidade de engajamento dos usuários na construção de sua reputação.

Desta forma, neste estudo, o material principal de estudo deriva-se do conteúdo gerado por usuários e a sua influência, através da estratégia de *crowdvoting* adotada pelos comércios

eletrônicos analisados, os quais foram segmentados e trabalhados por técnicas de aprendizado de máquina para a interpretação e validação do sentimento carregado neste conteúdo.

2.7 Inteligência coletiva

De acordo com Lévy (1998), a inteligência coletiva pode ser definida como uma inteligência distribuída por toda parte, incessantemente valorizada, coordenada em tempo real, que resulta uma mobilização efetiva das competências.

Numa reflexão sobre o arcabouço teórico de cada indivíduo, uma inteligência adquirida no decorrer de sua vida de forma única, cada indivíduo passa a ser detentor de uma sabedoria única, um conjunto de experiências pessoais que lançam uma visão única sobre qualquer problema que se apresente, não havendo assim um centro monopolizador da sabedoria, está que, em sua visão, erroneamente reprimida pelos métodos de avaliação sistemáticos da inteligência humana, e coordenadas para que tratem em conjunto de um problema específico, a partir da colaboração do saber individual, a fim de um resultado específico ao problema apresentado, apontando assim que a soma das partes se torna maior do que o todo.

Dentro desse universo, potencializamos a troca de conhecimento por irmos além do conhecimento explícito e explorando o conhecimento tácito de cada indivíduo que passa a ser uma variável a colaborar na busca da solução de um problema apresentado.

De acordo com Nonaka e Takeuchi (1997), temos como o conhecimento explícito, aquele feito por fatos, regras e relações políticas que podem ser codificadas e transmitidas em grande escala sem a necessidade de discussão. Esse pensamento também é corroborado por Wyatt (2001).

Por sua vez, o conhecimento tácito é pessoal e complexo, originado da experiência de um indivíduo dentro de um contexto específico (Vitelli, 2003). Neste último, temos as capacidades pessoais de cada indivíduo e uma transmissão diferenciada, que depende de interações prolongadas, erros e acertos (Castanheira, Peixoto & Cardoso, 2003).

Pressupõe-se desta forma que um grupo amplo de pessoas pode, em determinadas circunstâncias, ser mais “inteligente” do que qualquer um dos seus membros, conclusão essa firmada nos princípios da teoria Gestáltica, e confirmada por Wooley *et al* (2010), concluindo que a inteligência coletiva de um grupo de pessoas, ao ir explorar o conhecimento tácito deste grupo, se estende além das habilidades individuais de cada membro deste grupo, sendo isto conhecido como inteligência coletiva (Slawsby & Riviera, 2007).

Esta estrutura apresenta uma forma primária de inteligência coletiva, observada em pequenos grupos, que é o que Noubel (2004) chama de inteligência coletiva original. No entanto, segundo este, a inteligência coletiva original encontra dois limites naturais, o de número e o de espaço.

No primeiro, apenas um número limitado de participantes pode interagir de forma eficiente, caso contrário o elevado nível de complexidade passa a gerar maior ruído que resultados efetivos. Por sua vez, no segundo, o espaço, os participantes necessitam de se encontrar no mesmo espaço físico e a curta distância para que possam interagir.

Desta forma, quando o número de participantes e/ou a sua distância de intervenção se torna muito ampla, pode ocorrer a sua ruptura. Estas limitações expostas pela visão de Noubel (2004) têm sido mitigadas pela tecnologia. A internet tem removido a barreira do espaço e as estratégias na abordagem de problemas e na disponibilização de ferramentas para o gerenciamento de massas tem colaborado na redução do ruído.

Com a evolução da tecnologia e a maturação da internet, os seus participantes já não se posicionam como ouvintes passivos, mas atuam ativamente, manifestando sua opinião e compartilhando o conhecimento, seja através de *blogs*, *vlogs*, postagens em redes sociais ou em *wikis*.

Desta forma vê-se a internet tomando a forma de uma rede neural, criando uma consciência coletiva e única, o que também pode ser chamado de inteligência coletiva. Como ensina Lévy (1998), as tecnologias propiciam o caminho para que a humanidade construa um novo espaço antropológico, onde todos os seres humanos estarão conectados em tempo real.

2.8 Crowdsourcing

Dentro deste contexto, diversos teóricos se manifestaram quanto a possíveis tipologias e aplicações ao mais diversos tipos de *crowdsourcing*. Passa-se a análise do posicionamento dos principais autores:

2.8.1 Tipologia de Howe (2008)

Howe foi o primeiro autor a cunhar o termo de *crowdsourcing*, quando o fez de maneira genérica, como esperado de um conceito novo, adotando-o como um termo para um grupo muito variado de abordagens dentro do conceito de algo originado a partir da contribuição de

multidões. Dentro desse conceito, Howe (2008) descreve quatro categorias de *crowdsourcing*: *crowdfunding*, *crowdvoting*, *crowdcreation* e *crowdwisdom*.

2.8.1.1 CrowdFunding

Discorrendo sobre *crowdfunding*, Howe (2008) define-o como uma abordagem em que uma ideia é apresentada às massas para que estas a financiem, isto podendo ser utilizado para os mais diversos fins, seja para ajuda e apoio a catástrofes naturais ou financiamento para o lançamento de novos produtos ou campanhas promocionais (Bons *et al*, 2010).

Como introdutor ao conceito, Howe (2008), com sua tipologia, descreveu, sintetizou e organizava o *crowdfunding* como um processo, o que não só colaborou para a divulgação do conceito e a aplicabilidade do conceito dentro do meio acadêmico, ainda que sua tipologia não apresente o rigor científico, conforme criticado por Brabham (2010) ao propor sua tipologia; ainda assim Howe propiciou uma maior aceitação do público através de suas ilustrações no uso deste método. De acordo com estudo realizado pela Massolution², uma empresa especializada em soluções de *crowdfunding*, em 2011 em torno de 1,5 bilhões de dólares foram arrecadados e financiaram projetos através do *crowdfunding*³.

2.8.1.2 Crowdvoting

O segundo tipo apresentado por Howe (2008) diz respeito ao *crowdvoting*, onde é dada à uma massa de pessoas a possibilidade de manifestar a sua opinião através de uma votação ou classificação de dados. Estratégia utilizada na aquisição de dados voltados a formulação de preferências populacionais e de propaganda direcionada, bem como para a organização de grandes bibliotecas, como é o caso do Google que utiliza o volume de páginas com links direcionados de outros *sites* para categorizar a relevâncias das páginas em seu mecanismo de busca.

2.8.1.3 Crowdcreation

O terceiro tipo citado é o *crowdcreation* envolvido na criação de valor a partir da inovação ou da colaboração participativa das multidões frente a uma tarefa, casos como esse

² Empresa especializada em soluções de crowdfunding. Recuperado de :<http://www.massolution4.com/>. Acesso em 20/01/2020.

³ Dados Referentes a março de 2012. Recuperado de <http://news.netcraft.com/>. Acesso em 20/01/2020

podem ser observados na *Wikipedia* ou no *Youtube* que recebem o seu conteúdo, o qual acarreta a manutenção do fluxo de clientes da plataforma.

2.8.1.4 *CrowdWidsom*

No quarto e último tipo de tipologia proposta por Howe (2008) temos o *crowdwisdom* que é literalmente a sabedoria das massas ou a inteligência coletiva em si, conforme apontada por Lévy (1998). Dentro dessa esfera, Howe (2008), propõe três tipos de exploração do conteúdo gerado, sendo eles:

- ✓ *Idea jam*, que se traduz em uma grande sessão de *brainstorm* onde qualquer participante põe em voga qualquer questão/ideia que lhe venha a mente.
- ✓ *Crowdcasting*, onde uma pessoa/entidade relata um problema previamente identificado a massa na esperança de que algum dos integrantes e/ou a interação deles possa resolvê-lo.
- ✓ Mercados de previsões, onde utiliza-se a sabedoria das massas, para prever acontecimentos e resultados com maior previsão, em sintonia de certa forma com o *crowdvoting*. Previsões utilizando big-data, ou número de postagens em fóruns para definir um possível ganhador para algum prêmio é uma das possíveis aplicações.

2.8.2 *Tipologia de Brabham (2010)*

Brabham (2010) sugere quatro tipos de *crowdsourcing*: Descoberta e gerenciamento de conhecimento, difusão de busca, produção criativa com vetos e distribuições de tarefas que necessitem de inteligência humana.

2.8.2.1 *Descoberta e gerenciamento de conhecimento*

Nesta abordagem de acordo com Brabham (2010), desafia-se uma comunidade *on-line* a encontrar algum determinado tipo de informação e derivar a partir daí em conhecimento, ampliando a capacidade de descoberta de uma organização com poucos recursos. Parte-se da filosofia de que o conhecimento necessário existe e encontra-se fora da organização e que através de um processo bem gerido de utilização do conhecimento das massas para adquirir um conhecimento que se encontra difundido na rede.

2.8.2.2 Difusão de busca

É uma técnica de procura de conhecimento em que é provável que a resposta já exista, mas que esta não seja conhecida pela organização que a busca, desta forma a empresa busca encontrar o especialista, ou perito, no meio da massa para que este possa orientá-la no caminho da resposta. Tal processo é referido por Brabham (2010, p. 8) como “encontrar uma agulha em um palheiro”⁴.

2.8.2.3 Produção criativa com vetos

É uma forma que através da participação das massas no processo criativo de uma empresa, possa-se encontrar entre milhares de ideias uma ideia que supere as demais, desta forma o processo de veto permite encontrar as melhores respostas e ir fechando o cone do processo produtivo de modo imediato, limando assim parte da pesquisa de mercado que seria necessária, onde a empresa e a massa participam em conjunto em um processo de co-criação.

2.8.2.4 Distribuições de tarefas que necessitem de inteligência humana

É uma plataforma de solução de problemas complexos, onde estes são quebrados em tarefas com menor complexidade e dividida entre os indivíduos que compõe a massa de pessoas colaborando com o projeto, para que dessa forma possa-se utilizar a inteligência humana na abordagem de problemas complexos em grandes massas de dados. Nesse processo apesar de ser necessária a inteligência humana, normalmente os processos após serem divididos e simplificados exigem baixos níveis de criatividade e intelectualidade e ainda assim os componentes da massa são recompensados pela sua colaboração (Brabham, 2010).

Brabham (2008, 2009 e 2010) examina as aplicações de *crowdsourcing* e baseado nas definições de Howe (2006, 2008), as generaliza como um modelo estratégico para resolução de problemas que pode e deve ser utilizado pelas empresas. Estes trabalhos colaboram na ampliação do conceito e na sua consolidação dentro do meio científico, apresentando o tema através de estudos sobre os aspetos sócio demográficos dos participantes e da motivação destes na participação do *crowdsourcing*.

⁴ Tradução livre pelo autor do original em inglês: “*needle in the haystack*”.

2.8.3 Tipologia de Schenk e Guittard (2009, 2011)

Schenk e Guittard (2009) definem suas tipologias através de duas dimensões:

- A natureza do processo, se integrativa ou seletiva;
- Tipo da tarefa a ser efetuada, simples, complexa ou criativa.

Na natureza processual, o sistema se torna integrativo quando cada colaboração é tida como agregando valor a anterior e dirigidas a um resultado esperado, em contrapartida, se torna seletivo quando cada colaboração é comparada uma a uma para a escolha da melhor contribuição.

Desta forma Schenk e Guittard (2009, 2011), propõem uma das distinções fundamentais do *crowdsourcing*. Esta distinção se relaciona intrinsicamente com o tipo de tarefa a ser executada pelas multidões, que se por um lado pode ser simples, tal qual a tradução de palavras, também pode apresentar alta complexidade como a inovação de um produto; ou criativa, como a roteirização de peças publicitárias.

2.8.3.1 Utilizando crowdsourcing para tarefas simples

Nesse tipo de tarefa, o valor agregado não é derivado de habilidades individuais, mais se dá com a realização de tarefas simples em grande escala com baixo custo, ainda que o incentivo financeiro não vá além de um pequeno pagamento. (Schenk & Guittard, 2009). Desta forma, muitas vezes as pessoas atuam no *crowdsourcing* sem o perceberem que o estão fazendo.

Um exemplo deste sistema é a solução fornecida pelo reCaptcha, a ideia evolui de uma barreira criada para distinguir os acessos de usuários humanos dos de usuários controlados por computadores com objetivos escusos. Para isto apresenta-se uma palavra em uma imagem embaralhada de tal forma que representam dificuldades para os computadores convertê-las para texto.

Ao perceber que milhares de pessoas dispendiam tempo ao digitá-las diversas vezes por dia para acessar seus serviços na web, a fim de aproveitar a inteligência humana dispendida em compreender a palavra, passou a utilizar as palavras e os trechos de livros que *softwares* de digitalização apresentavam dificuldade de digitalizar, propiciando assim primeiro a segurança necessária ao acesso e em segundo um produto - digitalização de material gráfico em larga quantidade (Schenk & Guittard, 2009).

2.8.3.2 Crowdsourcing de tarefas complexas

Tarefas complexas podem ser definidas como uma tarefa que pode apresentar vários resultados potenciais, várias soluções e a presença de incerteza que requerem a compreensão do problema e de conhecimentos e habilidades específicas para a sua resolução (Campbell, 1988). Neste momento, uma empresa pode decidir se o seu grupo interno de especialistas pode se beneficiar de uma maior quantidade de opiniões e de visões distintas quanto as respostas do problema a fim de obter uma resolução mais satisfatória frente a complexidade do problema (Schenk & Guittard, 2011).

Neste modelo de *crowdsourcing* a empresa através de uma natureza seletiva das contribuições fornecidas pela multidão, seleciona as respostas mais condizentes com o problema para obter uma resposta adequada as suas necessidades. Este controle seletivo de massas de dados acaba por exigir um ferramental mais robusto por parte da empresa, e devido à necessidade de maior empenho cognitivo dos indivíduos que compõem a multidão, também necessita de um maior incentivo por parte da empresa a estes.

2.8.3.3 Crowdsourcing de tarefas criativas

As empresas que optam por este modelo não esperam resoluções de problemas, mas sim, de poder fazer uso da criatividade e da proximidade ao público que as massas geram, e devido a esta característica as recompensas ao grupo podem ser variadas, não sendo ligadas exclusivamente ao retorno financeiro (Amabile *et al.*, 2005).

Pode-se ver este conceito em prática nas lojas de aplicativos para celulares dos sistemas operacionais IOS e Android. As empresas disponibilizam inúmeras ferramentas e tutoriais (“passo a passo”) para a criação dos aplicativos, reduzindo o conhecimento técnico necessário para seu desenvolvimento.

Desta forma milhares de pessoas passam a ter acesso a ferramentas para desenvolver aplicativos que colaboram na experiência do usuário com seus produtos. Uma vez que o acesso é distribuído a todo aquele que manifeste interesse e há uma enxurrada de softwares disponibilizados as lojas de aplicativos, os mais criativos recebem um retorno positivo dos usuários.

2.8.4 Tipologia Geiger, Rosemann e Fielt

Definem o *crowdsourcing* como um sistema em que uma multidão de pessoas ajuda a solucionar um problema definido pelos donos do sistema. Assim para resolver um problema, o sistema precisa avaliar diversos aspectos do processo de *crowdsourcing* (Doan et al., 2011), tais quais:

- Definir que tipo de contribuições são aceitáveis;
- Como recrutar e manter os contribuidores;
- Como combinar as contribuições de forma a resolver o problema;
- Avaliar os contribuidores e suas contribuições.

Geiger *et al* (2011) distingue quatro tipos de sistema de *crowdsourcing*, servindo cada um para um propósito distinto, onde o primeiro é destinado a avaliação de algo (*crowdrating*), a criação de algo (*crowdcreating*), processamento de algo (*crowdprocessing*) e para resolução de alguma questão (*crowdsolving*).

Apesar de haver quatro tipos distintos, na prática observa-se uma interação entre as formas a fim de atingir os objetivos das empresas, combinando entre eles os componentes qualitativos e quantitativos de cada abordagem; este uso misto de sistemas pode ser observado nas estratégias adotadas por companhias como a Dell, Apple e Fiat na utilização do *crowdsourcing*. Um exemplo do uso de estratégia mista bem conhecido é o próprio Wikileaks onde um sistema de *crowdprocessing* aliado ao *crowdrating* garantem o bom funcionamento da ferramenta (Geiger *et al.*, 2011).

Desta forma, constrói-se um sistema adaptativo que passeia por entre as visões paradigmáticas do *crowdsourcing*, a fim de que se possa adaptar a abordagem, através de um ajuste fino, e se atinja os resultados esperados conforme cada situação.

2.9 Sistemas reputacionais

Antes da internet, um vendedor tinha de construir uma relação com o comprador, geralmente de forma presencial, onde este tinha de prover referências quanto a qualidade de seu produto/serviço. Muitos negócios acabavam por catalogar e tratar as reclamações, e os consumidores se baseavam pelas suas experiências anteriores e pelo boca-a-boca que chegava até eles.

Atualmente, porém, ao realizar transações na internet, temos diversos negócios acontecendo de forma anônima, em grande escala e em regiões distantes, inviabilizando muitas vezes a verificação destas referências da forma em que ocorriam antes da internet. Neste cenário que surgem os sistemas reputacionais, soluções estruturadas para coletar, distribuir e agregar o *feedback* dos consumidores que utilizaram aquele serviço ou adquiriram tal produto.

Ainda que poucos dos usuários que avaliam uns aos outros se conheçam, estes sistemas auxiliam a outros consumidores a decidir em quem confiar, encoraja um comportamento de confiança e detém a participação por aqueles que não são honestos (Resnick, et al, 2000).

Estes sistemas se propõem como uma alternativa de suporte a construção de confiança entre estranhos. Seguindo o caminho da construção de confiança entre duas pessoas que se conhecem, construímos vínculos de confiança ao partilharmos de alguma história em conjunto e a partir daí prospectamos o futuro de outras interações, decidindo se tem motivos para confiar ou desconfiar da outra parte. A partir daí criamos a expectativa de reciprocidade ou retaliação em interações futuras, o que cria o incentivo para o bom comportamento, incentivo este que Axlerod (1984) chamou de sombra do futuro.

Entre desconhecidos esta construção é mais complexa, uma vez que sem a convivência as garantias ficam frágeis demais, não havendo uma rede de interações que possa cobrar a reciprocidade e punir em caso de mal comportamento, e neste ponto que o sistema reputacional entra atuando como uma forma de restaurar a sombra do futuro de Axlerod (1984), por salvar e exibir todas as transações realizadas com a expectativa de que outras pessoas a verão e em caso de mal comportamento executaram a punição (no caso não adquirir o produto/serviço).

Esta é a ferramenta suporte para a estratégia do *crowdvoting*, implementada nos varejos eletrônicos para nortear e suportar o conteúdo gerado pelos usuários e para formar a rede social daquele comércio eletrônico.

2.10 Crowdvoting e estratégia de aplicação

Aprofundando o conceito de *crowdvoting*, indo além da posição definida por Howe (2008), pode se subdividir esse conceito a partir da construção de algumas práticas já fundamentadas na teoria de marketing e sua consolidação dentro do espaço web, a partir da utilização da inteligência coletiva e seus efeitos práticos na *performance* dos produtos.

A estratégia de *crowdvoting* consiste em propiciar um ambiente dentro dos limites digitais de uma entidade, por exemplo um comércio eletrônico de uma empresa de varejo (alvo deste estudo), onde se disponibiliza um canal para que a interação entre os usuários deste

ambiente possa ser registrada, acompanhada, visualizada e acessada por qualquer indivíduo por meio da internet.

Este ambiente precisa propiciar um espaço para que o usuário possa manifestar de forma livre e espontânea a sua percepção frente aos produtos/serviços ofertados e criticá-lo, podendo fazer isto de forma objetiva ou subjetiva. Usualmente os ambientes dentro desta estratégia oferecem espaço para as duas formas, sendo a objetiva uma nota que pode variar de acordo com a metodologia adotada de mensuração da plataforma, porém usualmente estrelas de 1 a 5, e um campo aberto para avaliação subjetiva onde o usuário pode gerar conteúdo livremente expressando assim para a comunidade a sua percepção sobre aquele produto/serviço.

Neste espaço observamos dois tópicos da literatura que se juntam para propiciar as bases desta estratégia o e-WoM e o UGC, que permitem criar um ambiente onde a comunidade é capaz de obter informações relativas aquele nicho de produto específico de seus pares e assim construir ou desconstruir a sua confiança no produto/serviço ofertado dentro de seu processo de decisão de compra.

Ainda dentro desta estratégia cada entidade tem adotado extensões distintas para o tratamento dos dados gerados e para a oferta de funcionalidades que complementem este processo. Estudos de Ma & Agarwal (2007) ressaltam a importância da verificação da identidade dos usuários por outros membros da comunidade, com informações disponibilizadas referentes a região geográfica e o perfil pessoal com dados sobre gênero, profissão e escolaridade que complementam a confiança a ser creditada àquela crítica.

Adicionalmente observamos incentivos feitos (não financeiros a fim de não descaracterizar a credibilidade do conteúdo gerado por estes usuários) dentro da estratégia para que os usuários manifestem sua opinião e apresentem um maior engajamento a comunidade e a marca, tais como insígnias de conquistas por publicar diversas análises ou pela quantidade de pessoas que foram auxiliadas pelas análises publicadas. Também se observa benefícios derivados do engajamento com a comunidade destes portais, onde o reconhecimento de seus pares exerce um efeito positivo em sua psique e consequentemente no reforço do engajamento deste com a empresa/comunidade (Forma, Ghose, & Wisenfeld; 2008).

Através deste canal pré-definido e monitorado – rede social, de compartilhamento de opiniões, alimentado pelas avaliações objetivas, conteúdo subjetivo criado por usuários (*UGC*) e o espaço de interação entre os usuários/consumidores, que propicia o diálogo entre a comunidade (*e-WoM*), observa-se a constituição de um ambiente de *crowdvoting*.

Dentro desta estratégia, a empresa pode orientar-se sob o ponto de vista de seu consumidor, trazendo o boca-a-boca para perto e agindo como uma terceira parte que observa

a interação e pode a partir daí optar em se manifestar diretamente ou em ajustar a sua oferta de produtos/serviços de forma discreta a fim de adequar a necessidade de seus consumidores e fortalecer assim a performance dos produtos ofertados e fortalecer a sua marca junto ao público.

3 METODOLOGIA DE PESQUISA

Propõe-se uma pesquisa quantitativa através da análise de bases de dados relativas a vendas e *reviews* de eletrônicos entre plataformas de comércio eletrônico (*Marketplaces*) de quatro empresas, três localizadas nos Estados Unidos e uma no Brasil. A finalidade deste estudo é analisar a influência do uso da estratégia de *crowdvoting* na *performance* dos varejos eletrônicos em melhorar seu interesse final, a venda de produtos/serviços.

Para esta finalidade avaliaremos os efeitos das análises dos usuários (dada de forma objetiva e subjetiva) dentro dos sistemas reputacionais disponibilizados por estes varejistas, para assim poder inferir os efeitos discorridos na literatura e observá-los em ação, para que possamos assim compreender se esta influência pode ser percebida e se os indicadores atuais (objetivos) são a melhor forma de análise da visão do usuário.

Outro ponto é analisar os efeitos observados em ambientes geoeconômicos diferentes, Brasil e Estados Unidos, para assim direcionar novos estudos e validar uma das hipóteses propostas anteriormente neste estudo (que os efeitos de aplicação desta estratégia em empresas cross-culturais se mantêm).

Neste estudo obtivemos dados secundários cedidos pela empresa Amazon, através da Universidade de Stanford, e através da plataforma Kaggle obtivemos dados das empresas americanas Bestbuy, ToysRus, totalizando as três bases americanas; para a base de dados brasileira, obtivemos os dados através da plataforma Olist que gerencia o *marketplace* de alguns comércios eletrônicos brasileiros.

Para a análise comparativa entre a influência do uso da estratégia de *crowdvoting* na *performance* dos *marketplaces* americanos e brasileiros, entendemos que é necessária um conjunto de dados representativos que pudéssemos comparar o fenômeno em ação entre estes dois mercados, em um primeiro momento validando o comportamento desta estratégia dentro do mercado americano, observando seus efeitos em um cenário econômico equivalente e com um público consumidor já habituado a compras na internet, e posteriormente, comparar as práticas observadas dentro dos dados do *marketplace* brasileiro.

Isto também se deve a necessidade de triangular os períodos de venda das três empresas americanas com a finalidade de montar um panorama que pudesse ser comparado com o cenário brasileiro dentro do recorte de tempo que temos. Dados de diferentes épocas podem carregar a influência de diversos fatores (economia, moda, acesso à *internet*) que poderia distorcer nossa análise.

Optamos assim por criar primeiramente o prisma do cenário americano, criando assim diretrizes que, se comprovadas – as estratégias de *crowdvoting* se comportarem de forma similar entre essas empresas ao longo dos períodos observados – podemos ter razoável segurança que esse panorama (que em duas das três empresas observadas se sobrepõem a janela de tempo analisada do Brasil) possa ser utilizado como meio de comparação entre os dois cenários, para o recorte das influências do *crowdvoting* dentro destas plataformas.

Assim a primeira parte é efetuar o comparativo e o entendimento do cenário americano, para a partir daí derivamos conclusões a serem observadas na empresa brasileira a fim de testarmos esta hipótese (H3).

3.1 Dados

A obtenção de dados para esta pesquisa acadêmica se mostrou um desafio, devido à natureza estratégica destes dados e ao alto custo financeiro que se implica na obtenção e no tratamento de amplas bases de dados. Esta dificuldade acarretou a obtenção de dados reais, porém seccionados e que apresentam períodos de dados divergentes para os mesmos campos de validação entre as quatro bases analisadas. Obtivemos dados de 1999 a 2013 para a Amazon, de 2014 a 2019 para a Bestbuy, de 2016 a 2017 para a ToyRus e de 2016 a 2017 para a Olist, base segregada do mercado brasileiro.

A partir das bases obtidas, temos um quadro mais completo de informações, propiciando um estudo estatístico mais amplo na base de dados da empresa Amazon e da Olist, foco de nossa comparação entre os mercados americanos e brasileiros; porém para estas bases observamos períodos de tempo distintos relevantes, com um deslocamento de tempo de três anos entre si, que carregará em si distorções relevantes relativas a evolução da internet, disponibilidade de conexão e adequação do público ao ambiente de compras dentro da internet.

Para mitigar esta questão e buscar isolar o fenômeno estudado (influência do *crowdvoting*) das variações e evoluções do mercado, optamos por primeiramente comparar a Amazon contra outros dois varejistas americanos, Bestbuy e ToyRus, que apresentassem períodos consonantes com os dados obtidos da empresa varejista brasileira, a fim de que pelos resultados obtidos da análise dos efeitos do *crowdvoting* no comportamento dos varejos eletrônicos americanos, se similares, pudessem permitir a comparação da base de dados da Amazon com a Olist (varejo eletrônico brasileiro), ou em caso negativo para que pudessemos comparar, ainda que com menos dados os varejos eletrônicos americanos Bestbuy e ToyRus com a varejista brasileira Olist.

Destas bases, outra dificuldade percebida foi a extensão dos dados e a capacidade de processamento necessária a fim de trabalhar as informações geradas por cada usuário, seus dados estatísticos e a análise de sentimento proposta. Para que isto se mostrasse viável, a fim de permitir a manipulação destes bancos de dados frente as limitações de processamento, optou-se em extrair amostras de tamanho reduzido, mas que fossem completas o suficiente para refletir a realidade da base original.

A amostra final escolhida é composta pelo segmento de eletrônicos destes quatro comércios eletrônicos, dentro dos períodos disponibilizados. Para a base de dados da Amazon dentro de eletrônicos optou-se em incorporar um filtro adicional, de trabalhar com celulares dentro do segmento de eletrônicos, a fim de obter uma massa de dados que cobrisse o período proposto, porém que se mostrasse viável de ser manipulada no ambiente computacional disponível. Estes dados se estendem por 14 anos (1999 a 2013), e mostram parte da evolução do engajamento do público do site frente ao uso de *crowdvoting*.

Esta amostra da base da Amazon resultou em 35.643 avaliações com o campo de score do produto e de revisão/comentário preenchidos.

Para a base de dados da Bestbuy optou-se em trabalhar com o intervalo de seis anos de dados disponíveis (2014 a 2019), que apresentasse o campo de score preenchido e de revisão/comentários preenchidos que resultou em uma amostra de 16.073 avaliações.

Para a base de dados da ToysRus optou-se em trabalhar com os últimos dois anos de dados disponíveis (2016 a 2017), e que apresentasse o campo de *score* e *review*/comentário preenchido, resultando em uma amostra de 1.676 avaliações.

Estas bases totalizaram na análise do comportamento de 53.392 avaliações de produtos ofertados no mercado norte americano entre os anos de 1.999 a 2019 em três grandes varejistas eletrônicos, dos quais dois se mantêm ativos e representativos até o presente (Amazon & Bestbuy).

Para a base de dados do varejo eletrônico brasileiro, aa Olist, optou-se em trabalhar com os últimos dois anos de dados disponíveis (2016 a 2017), e que apresentasse o campo de *score* e revisão/comentários preenchido. Esta amostra resultou em 41.203 avaliações, obtidas no esforço de obter uma massa de dados representativa que fizesse frente a quantidade de dados dos varejos norte-americanos disponível, a fim de obter uma melhor visão sobre os efeitos do *crowdvoting* nestes dois cenários.

Cada base de dados obtida apresenta um formato próprio, ainda que trate de campos equivalentes em sua maioria, estas foram inicialmente analisadas em sua própria estrutura, respeitando os campos disponibilizados em sua essência para os fins estatísticos.

Posteriormente as organizamos em arquivos de dados segregados, para que pudessem ter seus dados caracterizados, com os rótulos de campos normalizados e assim importados e trabalhados em softwares estatísticos e submetidos a análise de sentimentos através de técnicas de *machine learning*.

A estrutura dos dados pode disponibilizada para cada base pode ser observada no Anexo I deste trabalho.

A análise de sentimento proposta visa compreender o sentimento expressado por cada usuário em sua avaliação e a partir disto definir a polaridade dos comentários para aprofundar a nossa percepção sobre o sentimento de cada usuário e a extensão da influência do *crowdvoting* dentro da *performance* destes produtos a partir destes dados adicionais.

3.2 Análise de sentimentos por IA e *machine learning*

Análise de sentimentos, ou mineração de opiniões, é um campo da linguagem natural de processamento onde são construídos sistemas para identificar ou extrair opiniões contidas em textos. Usualmente para isto, além de identificar a opinião obtemos atributos de expressão que visam suprir informações relativas à polaridade da opinião – se o autor se expressa de forma positiva ou negativa frente ao tópico, o assunto sobre o que está discutindo e a pessoa ou entidade que expressa tal opinião.

A fim de compreender o funcionamento desta análise, primeiramente definimos o conceito de opinião que será examinado neste estudo. A informação textual pode ser categorizada entre dois grupos principais, sendo o primeiro fato e o segundo opiniões.

Fatos são expressões objetivas sobre algo, enquanto opiniões são expressões subjetivas que descrevem os sentimentos, visões e opiniões de pessoas quanto a um objeto ou assunto específico. No caso deste estudo, analisamos opiniões sobre o produto/serviço ofertado pelos varejos eletrônicos a qual este participa.

A análise de sentimentos, neste caso, pode ser modelada como uma forma de classificação onde dois problemas precisam de resposta, sendo o primeiro a classificação do texto em subjetivo ou objetivo e o segundo se a sentença exprimida reflete uma posição positiva, negativa ou neutra, também conhecida de polaridade. Neste estudo analisaremos a polaridade do campo de texto, a partir do conteúdo do usuário gerado, sem considerarmos o efeito subjetivo ou objetivo do campo, deixando isto a cargo da ferramenta que caracterizará a polaridade do comentário.

Dentro da opinião dentro de nosso estudo o usuário/cliente pode se manifestar a respeito do produto, de seus componentes, aspectos, atributos e recursos, porém dada a natureza do negócio, onde a entrega e o tempo para receber tal bem acabam impactando a percepção do usuário, também pode avaliar de forma subjetiva ou indireta o serviço associado àquele produto, podendo assim esta avaliação ser mista, negativa frente a parte do que foi ofertado, porém positiva a outro tópico – ponto analisado de forma indireta pela consideração do tamanho e caracteres utilizado em cada avaliação.

A utilização da análise de sentimento a partir de código estruturado e da inteligência artificial, nos permite lidar com grandes volumes de dados não estruturados e não organizados de forma ágil e com um critério consistente de análise – a partir do treino da máquina através dos dicionários escolhidos - nos permitindo dar sentido e significado ao volume de dados obtido pelas pesquisas, e-mails, bate papos, textos e no nosso caso presente, avaliações de produto/serviço.

A análise de sentimentos pode ser implementada de diversas formas ou por diversos algoritmos, que podem ser classificadas como baseada em regras, automatizada ou híbrida. Para este trabalho utilizamos a forma automatizada, que se baseia em um sistema que utiliza aprendizado de máquina para aprender sobre os dados a ele apresentados.

Este modelo de tarefa é comumente modelado como uma forma de classificação de problemas onde o classificador é alimentado com texto e retorna categorias – no nosso caso polaridade: neutra, positiva ou negativa.

Para que isto ocorra como esperado precisamos treinar este modelo e para isto utilizamos alguns dicionários dentro do algoritmo que passa a fazer processos preditivos em textos desconhecidos previamente ao colocá-los em vetores que são alimentados em modelos que geram marcações preditivas, no nosso caso a polaridade do comentário.

Dentro desta lógica, utilizamos duas plataformas distintas, escolhidas por sua maturidade, desenvolvimento da IA da máquina e a disponibilidade de dicionários com os idiomas observados a fim de ampliar a compreensão de nossa máquina.

Para as bases de dados americanas, utilizamos a plataforma Azure da Microsoft, através da API da *Lexicon Based Sentiment Analysis* e do software tensorflow do Google, que analisa o texto bruto do comentário e retorna uma pontuação entre 0 e 1, onde 1 indica sentimento positivo e notas próximas a 0 indicam sentimentos negativos.

Para a base da Olist, utilizamos a ferramenta *Meaning Cloud* que utiliza uma API por dentro do Microsoft Excel para analisar o texto bruto e pontuar os comentários em um *score* entre 0 e 1, onde 0 é sentimento negativo e 1 é sentimento positivo. A escolha da *Meaning*

Cloud se deve a necessidade de obter um dicionário em português brasileiro, robusto, que pudesse efetuar o treinamento da máquina para o reconhecimento dos sentimentos, já disponibilizada de forma estruturada pela ferramenta escolhida.

Para realizar as análises de sentimento nas bases de dados obtidas, separamos todo o conteúdo gerado pelos usuários de cada base de dados, entidade a entidade e de acordo com o seu idioma de escrita (inglês para as bases americanas e português brasileiro para a base brasileira).

Uma vez separada as bases, optou-se em analisar a polaridade das avaliações de duas formas distintas, a primeira a partir da subdivisão das avaliações pela nota concedida por cada usuário a partir da pontuação dada ao comentário a fim de obter uma métrica de validação que nos servirá de controle sobre a *performance* da máquina (a qual treinamos para executar a análise de sentimentos pela interpretação das avaliações).

Este controle é uma estratégia escolhida como sub-etapa para validação da *performance* dos dicionários utilizados nas análises automatizadas pelas inteligências artificiais escolhidas para a interpretação dos idiomas analisados (inglês e português brasileiro), servindo de apoio e contraponto para qualquer caso destoante que pudesse surgir durante as análises.

Para a validação inicial e controle, analisou-se a polaridade dos comentários a partir da nota dada ao *review* pelo usuário/cliente (pontuação definida no campo normatizado *Review Score*). Esta pontuação é definida pelo usuário que está realizando a avaliação e vai de 1 (menor nota possível) a 5 (maior nota possível), campo este que só aceita valores inteiros. Para isto assumimos a seguinte situação frente a pontuação concedida:

- *Score* 1 a 2: Polaridade negativa.
- *Score* 3: Polaridade neutra.
- *Score* 4 a 5: Polaridade positiva.

Com esta visão das bases de dados, as submetemos a análise de uma das duas ferramentas disponíveis neste trabalho para a análise de sentimentos computadorizada das avaliações concedidas para medição de sua polaridade a partir do aprendizado da máquina pelos dicionários constituídos para estas ferramentas, resultando em um novo arquivo de dados com os campos adicionais de polaridade e o score gerado pelo algoritmo que suporta a polaridade definida para cada conteúdo analisado.

Esta verificação servirá para efeito de comparação com o que expressado pelo usuário a partir do *UGC* deste contra a nota objetiva dada por ele a sua crítica. Devido a dificuldades inerentes ao lado humano do consumidor, e aos efeitos observados no processo de compra e

pela influência do *e-WoM*, acreditamos que o real capital econômico está entre as expressões contidas nestes comentários, e que desta forma estes constituem um indicador melhor ao grau de satisfação do consumidor com aquela compra.

A fim de validarmos esta hipótese (H2), realizamos a análise de sentimentos e posteriormente comparamos com os Scores apresentados para compreendemos se estes se espelham ou não.

3.3 Identificação de usuários e sigilo de dados sensíveis

Inicialmente é importante relatar que as bases de dados obtidas não permitem identificar seus usuários em suas informações sensíveis, todas apresentam dados públicos, disponibilizados em ambiente aberto e caracterizado por um campo de identificação único (id – identificação do usuário na plataforma analisada) referente ao cadastro daquele usuário dentro da plataforma da entidade em análise, variando esta nomenclatura entre as entidades, porém com o mesmo princípio lógico. Esse id apresentado não se qualifica como dado sensível, frente a legislação atual de proteção de dados, pois é um dado público fornecido a todo e qualquer usuário que opte em publicar um *review* que fica disposto e aberto ao público geral, sendo acessíveis por qualquer indivíduo a partir da página de venda do produto dentro da plataforma de comércio eletrônico analisada.

Tais dados não nos permitem identificar as pessoas que se registraram sob os apelidos ou nome dos usuários, e apenas caracterizam que cada usuário seja único e que possamos observar o comportamento deste e se for o caso tratar comentários em duplicidade.

Adicionalmente é relevante pontuar que o uso dos referidos dados obtiveram a aprovação formal para sua utilização. Para os dados da empresa Amazon, está em conjunto com a Universidade de Stanford, que faz a custódia de seus dados, autorizou o seu uso em trabalhos acadêmicos, não havendo qualquer conflito ou violação de privacidade com o uso do referido banco de dados.

Para os demais dados (Bestbuy, ToyRus & Olist - br), estas bases foram disponibilizadas em ambiente do Kaggle, uma subsidiária da empresa Google LLC que publica e oferta base de dados para fins de pesquisa e de construção de modelos para pesquisadores e engenheiros, a partir da parceria com diversas empresas que são encorajadas a disponibilizar seus dados para o avanço da ciência na área da ciência de dados. Estas bases são públicas, e anonimizadas, apresentam dados reais destas entidades, e podem ser utilizadas para fins acadêmicos.

3.4 Teste de correlação

Optou-se para esta tarefa utilizar dois softwares, o Microsoft Excel para a manipulação dos dados e formatação de dados para a importação no software estatístico e a máquina da linguagem R, a fim de efetuar os estudos estatísticos de correlação entre as variáveis observadas.

Para teste da hipótese proposta, selecionamos cinco variáveis, sendo estas:

- *Score* do produto: Avaliação do produto em escala de 1 a 5 fornecido pelo usuário.
- Polaridade da *review*: Através da análise de sentimentos através de duas ferramentas, a primeira através do MS Excel por intermédio do MPQA *Subjectivity Lexicon*, por dentro da Azure da Microsoft (para os textos em inglês) e por intermédio da MeaningCloud para os algoritmos de aprendizado de máquinas com dicionários em textos em português.
- Quantidade de caracteres no *review*: número de caracteres no *review*, já descontado os espaços em branco.
- Avaliação da ajuda do *review*: Fração de usuários que entenderam que o *review* útil.
- Preço do produto (*Amazon e Olist-br*): Preço de venda anunciado para o produto avaliado.

3.4.1 Teste de correlação de Pearson

Para estas variáveis foi realizada a análise da correlação das variáveis entre si, através do teste de correlação linear de Pearson, este teste avalia a correlação por mensurar o valor das variáveis X e Y em nível intervalar ou de razões. A partir desta análise o teste fornece o Coeficiente de Pearson – r – que pode variar de -1 a +1, e quanto mais próximos destes valores, mais forte a associação das variáveis em análise. O escore zero deste coeficiente indica ausência de correlação entre as variáveis. Desta forma, realizamos as seguintes análises:

- 1- Analisar se os produtos que apresentam *scores* mais altos (*review_score*) ou mais baixos apresentam maior número de caracteres no *review* (*número_de_caracteres*), o que sugeriria uma maior dedicação dos usuários aos produtos que lhes causam algum tipo de frustração.
- 2- Correlação da polaridade do *review*, se positivo, neutro ou negativo (*polaridade*), com o *score* do produto (*review_score*).
- 3- Avaliação da correlação do número de caracteres (*número_de_caracteres*) e a polaridade (*polaridade*) do *review*.

- 4- Avaliação da correlação do *score* do produto (*review_score*) com o preço do produto (*product_price*).
- 5- Avaliação da correlação do número de caracteres do *review* (*número_de_caracteres*) com o preço do produto (*product_price*).

Estas análises inicialmente abordam toda a amostra trabalhada nessa dissertação, porém para uma segunda análise com o objetivo de complementar a visão do comportamento da massa de usuário que dispõem de seu tempo para avaliar os produtos, dividimos a amostra de acordo com a percepção que o usuário teve do produto, sua polaridade, positiva ou negativa, afim de compararmos as variáveis frente a produtos bem avaliados e mal avaliados. O objetivo desta separação é testar a hipótese diretriz desta dissertação, de que a interação dos usuários e suas avaliações acabam por impactar o desempenho dos produtos por eles avaliados.

3.4.2 Teste de correlação de Spearman

É uma medida não paramétrica de correlação de postos (dependência estatística entre a classificação de duas variáveis). O coeficiente avalia com que intensidade a relação entre duas variáveis pode ser descrita pelo uso de uma função monótona. A correlação de Spearman entre duas variáveis é igual à correlação de Pearson entre os valores de postos daquelas duas variáveis. Enquanto a correlação de Pearson avalia relações lineares, a correlação de Spearman avalia relações monótonas, sejam elas lineares ou não. Se não houver valores de dados repetidos, uma correlação de Spearman perfeita de +1 ou -1 ocorre quando cada uma das variáveis é uma função monótona perfeita da outra.

Desta forma, realizamos as seguintes análises:

- 1- Analisar se os produtos que apresentam *scores* mais altos (*review_score*) ou mais baixos apresentam maior número de caracteres no *review* (*número_de_caracteres*), o que sugeriria uma maior dedicação dos usuários aos produtos que lhes causam algum tipo de frustração.
- 2- Correlação da polaridade do *review*, se positivo, neutro ou negativo (*polaridade*), com o *score* do produto (*review_score*).
- 3- Avaliação da correlação do número de caracteres (*número_de_caracteres*) e a polaridade (*polaridade*) do *review*.
- 4- Avaliação da correlação do *score* do produto (*review_score*) com o preço do produto (*product_price*).

- 5- Avaliação da correlação do número de caracteres do *review* (*número_de_caracteres*) com o preço do produto (*product_price*).

3.4.3 Teste de correlação de Kendall

É uma medida de correlação de postos, ou seja, verifica a semelhança entre as ordens dos dados quando classificados por cada uma das quantidades. Intuitivamente, a correlação de Kendall entre duas variáveis será elevada se as observações tiverem uma classificação semelhante (ou idêntica no caso de correlação igual a 1), comparadas as duas variáveis. Por classificação, entende-se a descrição das posições relativas das observações no interior de cada variável. A correlação de Kendall será baixa quando as observações tiverem uma classificação diferente (ou completamente diferente no caso de correlação igual a -1) comparadas as duas variáveis.

Desta forma, realizamos as seguintes análises:

- 1- Analisar se os produtos que apresentam *scores* mais altos (*review_score*) ou mais baixos apresentam maior número de caracteres no *review* (*número_de_caracteres*), o que sugeriria uma maior dedicação dos usuários aos produtos que lhes causam algum tipo de frustração.
- 2- Correlação da polaridade do *review*, se positivo, neutro ou negativo (*polaridade*), com o *score* do produto (*review_score*).
- 3- Avaliação da correlação do número de caracteres (*número_de_caracteres*) e a polaridade (*polaridade*) do *review*.
- 4- Avaliação da correlação do *score* do produto (*review_score*) com o preço do produto (*product_price*).
- 5- Avaliação da correlação do número de caracteres do *review* (*número_de_caracteres*) com o preço do produto (*product_price*).

3.5 Análise de sentimentos por IA e machine learning

A partir das bases obtidas, analisou-se as bases frente a polaridade dos *reviews* a partir de duas formas distintas. A primeira foi a subdivisão dos comentários a partir das notas dos *reviews* (*reviews score*) subdividindo esta base a partir das notas obtidas.

- *Score* 1 a 2: Polaridade negativa.
- *Score* 3: Polaridade neutra.

- Score 4 a 5: Polaridade positiva.

Com esta visão das bases, as submetemos a análise de duas ferramentas para a análise de sentimentos dos comentários a fim de medir a polaridade a partir do aprendizado da máquina e de dicionários constituídos dentro das ferramentas disponibilizadas. Para esta atividade utilizamos a plataforma Azure, através da API da *Lexicon Based Sentiment Analysis*, que analisa o texto bruto do comentário e retorna uma pontuação entre 0 e 1, onde 1 indica sentimento positivo e notas próximas a 0 indicam sentimentos negativos. Esta ferramenta foi utilizada para as bases internacionais (Amazon, ToyRus & Bestbuy), por conter o dicionário em inglês formalizado para o algoritmo.

Para a base da Olist, utilizamos a ferramenta *Meaning Cloud* que utiliza uma API por dentro do Excel para analisar o texto bruto e pontuar os comentários em um *score* entre 0 e 1, onde 0 é sentimento negativo e 1 é sentimento positivo. A escolha da *Meaning Cloud* se deve a necessidade de obter um dicionário em português brasileiro que pudesse efetuar o treinamento da máquina para o reconhecimento dos sentimentos, já disponibilizada de forma estruturada pela ferramenta escolhida.

4 Análise Dos Dados

Através das bases de dados obtidas, submetemos estas a tratamentos de forma a fim de segmentarmos as amostras discutidas no tópico anterior (dados) e as carregamos no software estatístico R. A partir daí efetuamos as análises estatísticas fundamentais de seus atributos e aplicamos testes de correlação entre eles.

Para estes testes realizamos as análises a partir de duas visões distintas, a primeira sessão divide a polaridade dos comentários (Positivos, Negativos ou Neutros) a partir do *score* objetivo dos *reviews* (notas de 1 a 5 dadas pelos usuários à aquele produto ou serviço). Na segunda seção efetuamos esta divisão a partir da análise de sentimentos realizada por *machine learning*, para observamos as diferenças presentes entre estas duas visões.

Para estes testes optamos em realizar três tipos de correlações a fim de obter uma visão global de seu comportamento, são estas: Pearson, Spearman e Kendal, os quais foram realizados para cada amostra completa e depois pela divisão de acordo com a polaridade dos comentários observados.

Após o teste de correlação, ainda para cada base efetuamos regressões lineares entre as variáveis a fim de analisar o seu comportamento e ao final realizamos regressões lineares múltiplas para completar a visão dos modelos criados para cada varejo eletrônico.

Ao final destas análises confrontamos as três bases internacionais entre si, para comparamos os efeitos do uso de *crowdvoting* dentro do sistema reputacional e assim buscar uma validação do cenário americano para que fosse o guia de nosso comparativo ao mercado brasileiro. Posteriormente comparou-se o resultado obtido desta análise com os resultados obtidos da análise do cenário brasileiro a partir da base de dados da Olist a fim de identificar se os comportamentos observados no cenário americano se refletem no cenário nacional, e assim confirmam a hipótese de que o *crowdvoting* afeta a *performance* dos produtos.

Para a análise das correlações, a fim de entender o comportamento da massa de usuários que efetua a avaliação dos produtos, realizamos as correlações nas amostras de 35.643 registros de avaliações de eletrônicos da Amazon, 16.073 registros de avaliações da Bestbuy, 1.676 registros de avaliações da ToysRus e 41.203 registros de avaliações da Olist; e posteriormente aferimos a correlação entre as variáveis a partir de um filtro baseado na polaridade do comentário, se neutro, positivo ou negativo.

E para a conclusão confrontou-se o resultado obtido nas bases americanas (Amazon, Bestbuy e ToyRus) com a base brasileira (Olist) a fim de entender se o cenário brasileiro

apresenta o mesmo comportamento observado no cenário americano e assim corroborando com a visão de que *crowdvoting* afeta a *performance* de vendas de produtos.

4.1 Amostra – Amazon

4.1.1 Amostra completa

Inicialmente conduzimos o teste de correlação de Pearson na amostra completa do *marketplace* Amazon, conforme o quadro (Tabela 1) que apresenta a correlação entre as diversas variáveis que compõem os atributos desta amostra.

Dos pontos que corroboram a visão de impacto relativo entre os componentes do *crowdvoting* podemos observar correlações de intensidade baixa a moderada atuando entre o auxílio do comentário e o número de caracteres dedicado a este (N° de Char x Review Help – 22,18%), indicativo de que a comunidade não se guia exclusivamente pelas avaliações objetivas, mas lê e se manifesta frente ao texto subjetivo das críticas.

Outro ponto observado que apresenta baixa a moderada correlação é o número de caracteres – indicando um aumento ou incentivo ao uso de argumentos subjetivos – em produtos de maior preço (N° de Char x Price). Corrobora com a literatura discutida anteriormente de processo decisório de compra com os pontos de insatisfação e satisfação exercendo influência no consumidor.

Nos pontos adicionais para a correlação de Pearson observamos correlações de baixa intensidade e outras próximas a zero, sendo assim desprezadas.

É importante ressaltar que, conforme Morôco (2014, p. 34-35):

O valor absoluto de correlação indica a intensidade da associação. De uma forma geral nas ciências sociais e humanas, mas definições precisas, consideramos que as correlações são: (i) fracas quando o valor absoluto de r ($|r|$) é inferior a 0,25. (ii) são moderadas para $0,25 \leq |r| < 0,5$; (iii) são fortes para $0,5 < |r| < 0,75$ e (iv) são muito fortes se $|r| \geq 0,75$.

Tabela 1: Correlação de Pearson - Amostra completa - Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,02970317	0,10672970	0,17694140	0,22176230
Review Score	-	-	-0,06077895	0,06455016	-0,05344780
Score (Sent)	-	-	-	0,03719594	0,03987905
Price	-	-	-	-	0,06372439
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-2,97%	10,67%	17,69%	22,18%
Review Score	-	-	-6,08%	6,46%	-5,34%
Score (Sent)	-	-	-	3,72%	3,99%
Price	-	-	-	-	6,37%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Correlação de *Spearman* em amostra completa do marketplace Amazon:

Tabela 2: Correlação de Spearman - Amostra completa – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,12050870	-0,08196404	0,27434530	0,24117770
Review Score	-	-	0,19189620	0,03525449	-0,06265389
Score (Sent)	-	-	-	0,03223519	-0,00666706
Price	-	-	-	-	0,08935971
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-12,05%	-8,20%	27,43%	24,12%
Review Score	-	-	19,19%	3,53%	-6,27%
Score (Sent)	-	-	-	3,22%	-0,67%
Price	-	-	-	-	8,94%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Dentro da correlação de Spearman (Tabela 2), por sua característica de explorar as relações de forma linear e não linear observamos que o efeito observado pela correlação de Pearson se intensifica e para algumas variáveis toma sentido oposto, valor negativo de correlação.

Por esta visão observamos a intensificação das correlações de número de caracteres contra preço e auxílio da crítica subjetiva (*Nº de Char x Price*, *Nº de Char x Review Help*) em que ambos apresentam correlação moderada entre si. Um ponto divergente por esta visão é a inversão do sentido da correlação do Score Sent (nota subjetiva) com o número de caracteres da crítica subjetiva (*Nº de Char x Score (Sent)*) que apresentam uma correlação negativa de 8,20%.

Este ponto nos leva a crer a confirmação da teoria do *e-WoM* da forma como se dá destaque na literatura (Christodoulides et al, 2012; Grégoire et al, 2014), que avaliações de insatisfação contam com maior esforço de disseminação desta informação por parte do consumidor.

Correlação de Kendall em amostra completa do *marketplace* Amazon:

Tabela 3: Correlação de Kendall - Amostra completa – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,08861983	-0,08604986	0,18562430	0,18769150
Review Score	-	-	0,14226530	0,02738596	-0,05445630
Score (Sent)	-	-	-	0,02189470	-0,00525065
Price	-	-	-	-	0,06978472
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-8,86%	-8,60%	18,56%	18,77%
Review Score	-	-	14,23%	2,74%	-5,45%
Score (Sent)	-	-	-	2,19%	-0,53%
Price	-	-	-	-	6,98%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Para a consideração das correlações de Kendall (Tabela 3), uma vez que sua finalidade é analisar a correlação de dois termos frente a sua classificação, destacamos como ponto interessante o resultado de duas variáveis que representam a avaliação objetiva e subjetiva em foco deste estudo, sendo estas Review Score e Score (Sent) respectivamente.

A partir desta visão vemos uma correlação baixa entre a estrutura de classificação destas duas variáveis e em sentidos opostos (Review Score x Score (Sent) de -5,45%, ainda que busquem demonstrar o mesmo posicionamento, indicando outra suspeita do estudo que é o descasamento entre a avaliação objetiva, comumente utilizada para classificar e trabalhar os comentários e a real percepção do consumidor frente aquela avaliação.

4.2 Amostra - Bestbuy

4.2.1 Amostra completa

Correlação de Pearson (Tabela 4) em amostra completa do *marketplace* Bestbuy:

Tabela 4: Correlação de Pearson - amostra completa – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,09561242	0,12692120
Review Score	-	-	-0,04527279
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-9,56%	12,69%
Review Score	-	-	-4,53%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Frente as bases disponíveis fomos capazes de efetuar a análise da correlação entre as variáveis de número de caracteres, review Score e o Score frente a análise de sentimentos realizada. Por esta visão visamos analisar o engajamento criado a partir do número de caracteres dedicado a cada crítica e a relação que o score objetivo apresente com o subjetivo.

Desta forma observamos, correlações baixas a moderadas – partindo dos princípios de análise de comportamentos humanos, onde 50% de correlação já poderia expressar uma possível forte correlação (Marôco, 2014), que entre as avaliações – Review Score (objetivo) e Score (Sent) (Subjetivo), temos uma correlação linear de -4,53%. A direção do sinal e o grau de força se mantém próximos a amostra da Amazon, indicando assim o mesmo comportamento.

Para o cruzamento entre número de caracteres e a avaliação objetiva (Nº de Char x Review Score), observamos uma correlação negativa de -9,56%, indicando o esperado pela

literatura do e-WoM, (Christodoulides et al, 2012; Grégoire et al, 2014) ainda que com baixa força, que notas maiores implicam em comentários menores.

Na análise de correlação de avaliação subjetiva e o número de caracteres (Score(Sent) x N° de Char) temos um valor de 12,69%, demonstrando o efeito oposto da correlação anterior, porém acompanhando o observado na base da Amazon. Esta análise mostra uma correlação ligeiramente mais forte e de mesmo sentido, indicando que a o sentimento subjetivo obtido por nossas análises tende a acompanhar o volume de esforço empregado. Isto não necessariamente contradiz a posição do *e-WoM*, uma vez que o material para a análise de sentimento é o conteúdo dos comentários, logo os caracteres utilizados.

Correlação de Spearman em amostra completa do *marketplace* Bestbuy:

Tabela 5: Correlação de Spearman - Amostra completa – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,10390450	-0,25684860
Review Score	-	-	0,19393080
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	10,39%	-25,68%
Review Score	-	-	19,39%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Neste recorte (Tabela 5) podemos observar a intensificação das correlações de número de caracteres e a análise objetiva e subjetiva, com inversão do sinal (Nº de Char x Review Score e Nº de Char x Score(Sent)), apontando que em análises não lineares a direção se inverte.

Nota-se que o movimento se mantém próximo ao observado na Amazon, ainda que em um dos casos com direção oposta. Obtivemos na análise da Amazon para a correlação de (Nº de Char x Review Score) um valor de -12,05%, frente a 10,39%. Já para a correlação de Nº de Char x Score (Sent) temos na amostra da Amazon um valor de -8,20% frente a -25,68%.

Deste cenário observamos uma intensificação nos valores obtidos pela correlação de caracteres e o Score (Sent), indicando um comportamento mais forte porém de direção igual dos consumidores desta plataforma em se manifestar na escrita de suas avaliações, ainda mais quando estas tomam um caráter negativo, o que reforça a teoria atual do *e-WoM* (Christodoulides et al, 2012; Grégoire et al, 2014).

Aqui também ressaltamos a correlação entre o Review Score x Score(Sent), análise objetiva e subjetiva, que apresentam a mesma direção e um valor moderado de 19,39%, indicando que nesta plataforma, para a amostra analisada, observamos uma certa coerência entre os índices, em consonância ao observado na amostra da Amazon, por esta visão.

Correlação de Kendall em amostra completa do *marketplace* Bestbuy:

Tabela 6: Correlação de Kendall - Amostra completa – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,08294575	-0,17779800
Review Score	-	-	0,15479640
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-8,29%	-17,78%
Review Score	-	-	15,48%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Para a consideração das correlações de Kendall (Tabela 6), uma vez que sua finalidade é analisar a correlação de dois termos frente a sua classificação, destacamos como ponto interessante o resultado de duas variáveis que representam a avaliação objetiva e subjetiva em foco deste estudo, sendo estas Review Score e Score (Sent) respectivamente.

A partir desta visão vemos uma correlação baixa entre a estrutura de classificação destas duas variáveis (Review Score x Score (Sent)) de 15,48% frente ao de 14,23% da base de dados da Amazon, valores muito próximos e mostrando a consistência do cenário entre elas.

4.3 Amostra - ToyRus

4.3.1 Amostra completa

Correlação de Pearson (Tabela 7) em amostra completa do *marketplace* ToyRus:

Tabela 7: Correlação de Pearson - Amostra completa – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,15101760	0,11373980
Review Score	-	-	-0,03079551
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-15,10%	11,37%
Review Score	-	-	-3,08%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Na base da ToyRus a análise da correlação entre as variáveis de número de caracteres, review Score e o Score visou analisar o engajamento criado a partir do número de caracteres dedicado a cada crítica e a relação que o score objetivo apresente com o subjetivo.

Desta forma observamos, correlações baixas a moderadas – partindo dos princípios de análise de comportamentos humanos, onde 50% de correlação já poderia expressar uma possível forte correlação, que entre as avaliações – Review Score (objetivo) e Score(Sent) (Subjetivo), temos uma correlação linear de -3,08% frente a -4,53% da BestBuy e -5,34% da Amazon, indicando assim o mesmo comportamento.

Para o cruzamento entre número de caracteres e a avaliação objetiva (Nº de Char x Review Score), observamos uma correlação negativa de 15,10%, enquanto na BestBuy obtivemos uma negativa de 9,56%, indicando comportamentos semelhantes e o esperado pela literatura do e-WoM, ainda que com baixa força, que notas maiores implicam em comentários menores.

Na análise de correlação de avaliação subjetiva e o número de caracteres (Score(Sent) x Nº de Char) temos um valor de 11,37%, frente a 12,69% na BestBuy e 10,67% na Amazon, demonstrando comportamentos similares novamente.

Correlação de Spearman (Tabela 8) em amostra completa do *marketplace* ToyRus:

Tabela 8: Correlação de Spearman - Amostra completa – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,11640350	-0,21615540
Review Score	-	-	0,26372930
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-11,64%	-21,62%
Review Score	-	-	26,37%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Na análise de Spearman nota-se que o movimento se mantém próximo ao observado na Amazon, na análise da Amazon para a correlação de (Nº d Char x Review Score) um valor de -12,05%, frente a -11,64%. Já para a correlação de Nº de Char x Score (Sent) temos na amostra da Amazon um valor de -8,20% frente a -21,62%, mostrando maior força, porém sentido igual.

Aqui também ressaltamos a correlação entre o Review Score x Score(Sent), análise objetiva e subjetiva, que apresentam a mesma direção e um valor moderado de 19,19% na Amazon, 19,39% na BestBuy enquanto aqui observamos 26,37%, indicando que nesta plataforma, para a amostra analisada, observa-se uma certa coerência entre os índices, em consonância ao observado nas demais amostra americanas.

Correlação de Kendall (Tabela 9) em amostra completa do *marketplace* ToyRus:

Tabela 9: Correlação de Kendall - Amostra completa – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,09255330	-0,14639610
Review Score	-	-	0,20911900
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-9,26%	-14,64%
Review Score	-	-	20,91%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Para a consideração das correlações de Kendall, destacamos como ponto interessante o resultado de duas variáveis que representam a avaliação objetiva e subjetiva em foco deste estudo, sendo estas Review Score e Score (Sent) respectivamente.

A partir desta visão vemos uma correlação baixa a moderada entre a estrutura de classificação destas duas variáveis (Review Score x Score (Sent)) de 20,91%, enquanto na Bestbuy obtivemos 15,48% e na Amazon 14,23%, valores próximos e mostrando a consistência do cenário entre elas.

4.4 Análise de sentimento a partir de IA – Azure MS e MeaningCloud's

Análise da polaridade dos comentários a partir da ferramenta Azure da Microsoft a partir de processamento de idioma natural em inglês por uma coleção de algoritmos de Inteligência Artificial e aprendizado de máquina para que esta efetue a leitura dos comentários e a partir da análise do texto bruto busca informações relativas a sentimentos positivos e negativos e os classifica entre 0 e 1, onde 1 é a mais positiva, para classifica-los. Adicionalmente para a base de dados em português (Olist) utilizamos a ferramenta da *Meaning Cloud* para efetuar a interpretação do texto bruto em português brasileiro e a partir do seu algoritmo utilizar a Inteligência Artificial e o aprendizado de máquina para classificar os comentários.

4.4.1 Amostra Amazon

4.4.1.1 Amostra com polaridade neutra

Correlação de Pearson em amostra com polaridade neutra (Tabela 10) do *marketplace* Amazon – análise inicial:

Tabela 10: Tabela de correlação de Pearson – Amostra neutra - Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,05518685	0,08819398	0,18028610	0,15959600
Review Score	-	-	-0,03217707	0,09561335	-0,11593910
Score (Sent)	-	-	-	0,03478577	-0,02491474
Price	-	-	-	-	0,07614760
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	5,52%	8,82%	18,03%	15,96%
Review Score	-	-	-3,22%	9,56%	-11,59%
Score (Sent)	-	-	-	3,48%	-2,49%
Price	-	-	-	-	7,61%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como Neutros pela análise de sentimentos feita por técnicas de *machine Learning* vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC). Vê-se que a correlação entre os dois se apresenta como baixa e de sentido oposto, indicando uma correlação inexistente entre os dois ou não linear.

Adicionalmente podemos observar correlações de intensidade baixa a moderada entre o número de caracteres (Nº de Char) e Preço (Price), correlação de 18,03% e Auxílio da crítica (Review Help), correlação de 15,96%. A correlação indicada pela correlação do número de caracteres e o Review Help, ainda que baixa a moderada, indica que as críticas feitas são lidas por outros usuários, que avaliaram os reviews de seus pares, e desta forma reforçam o engajamento da comunidade ao participarem e manterem vivo o sistema reputacional destes varejos – hipótese H1.

Correlação de Spearman em amostra com polaridade neutra (Tabela 11) do *marketplace* Amazon – análise inicial:

Tabela 11: Tabela de correlação de *Spearman* – Amostra neutra – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,03108560	-0,00109162	0,30112550	0,14233510
Review Score	-	-	0,09051213	0,08692172	-0,11245520
Score (Sent)	-	-	-	0,03960112	-0,02561497
Price	-	-	-	-	0,06653229
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	3,11%	-0,11%	30,11%	14,23%
Review Score	-	-	9,05%	8,69%	-11,25%
Score (Sent)	-	-	-	3,96%	-2,56%
Price	-	-	-	-	6,65%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Observando ainda a correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), correlação de 9,05%. Vemos que a correlação entre os dois se mantém baixa, mesmo na avaliação não linear, porém de mesmo sentido, corroborando para a confirmação da hipótese H2 deste trabalho.

Correlação de Kendall em amostra com polaridade neutra (Tabela 12) do *marketplace* Amazon – análise inicial:

Tabela 12: Tabela de correlação de Kendall – Amostra neutra – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,02352136	-0,03501091	0,20388560	0,11128520
Review Score	-	-	0,06609916	0,06599679	-0,10194480
Score (Sent)	-	-	-	0,02639957	-0,02022299
Price	-	-	-	-	0,05313738
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	2,35%	-3,50%	20,39%	11,13%
Review Score	-	-	6,61%	6,60%	-10,19%
Score (Sent)	-	-	-	2,64%	-2,02%
Price	-	-	-	-	5,31%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score (Sent), avaliações objetivas e subjetivas, apresentando 6,61% e assim não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho.

4.4.1.2 Amostra com polaridade positiva

Correlação de Pearson em amostra com polaridade positiva (Tabela 13) do *marketplace* Amazon – análise inicial:

Tabela 13: Tabela de correlação de Pearson – Amostra positiva – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,12313980	0,15099820	0,11433650	0,21033380
Review Score	-	-	0,08762308	0,03183888	-0,04976920
Score (Sent)	-	-	-	0,02783936	0,03739310
Price	-	-	-	-	0,05993821
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-12,31%	15,10%	11,43%	21,03%
Review Score	-	-	8,76%	3,18%	-4,98%
Score (Sent)	-	-	-	2,78%	3,74%
Price	-	-	-	-	5,99%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como Positivos pela análise de sentimentos feita por técnicas de *machine Learning* vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta 8,76% de correlação. Vemos que a correlação entre os dois se apresenta como baixa, indicando uma correlação inexistente entre os dois ou não linear.

Adicionalmente podemos observar correlações de intensidade baixa a moderada entre o número de caracteres (Nº de Char) e Preço (Price), correlação de 11,43% e Auxílio da crítica (Review Help), correlação de 21,03%, indicando que as críticas feitas são lidas por outros usuários e desta forma reforçam o engajamento da comunidade ao participarem e manterem vivo o sistema reputacional destes varejos – hipótese H1.

Observamos que á uma variação interessante frente a amostra neutra, que indica um maior engajamento da comunidade na leitura de comentários positivos frente aos neutros e que

a avaliação retratada na nota objetiva parece não apresentar muita ligação com o texto produzido pelos usuários, indicativo de nossa hipótese H2.

Correlação de Spearman em amostra com polaridade positiva (Tabela 14) do *marketplace* Amazon – análise inicial:

Tabela 14: Tabela de correlação de Spearman – Amostra positiva – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,15029170	0,14716880	0,18261780	0,20138870
Review Score	-	-	0,06159514	-0,04745958	-0,05109978
Score (Sent)	-	-	-	0,05210172	0,03633992
Price	-	-	-	-	0,06630423
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-15,03%	14,72%	18,26%	20,14%
Review Score	-	-	6,16%	-4,75%	-5,11%
Score (Sent)	-	-	-	5,21%	3,63%
Price	-	-	-	-	6,63%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Por Spearman, a correlação de Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta o valor de 6,16%, um valor ainda menor do que o obtido na correlação linear de Pearson. Também salientamos a inversão da correlação entre a variável de preço (Price) e a nota objetiva (Review Score), mostrando uma correlação baixa, porém invertida.

Correlação de Kendall em amostra com polaridade positiva (Tabela 15) do *marketplace* Amazon – análise inicial:

Tabela 15: Tabela de correlação de Kendall – Amostra positiva – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,11768750	0,09926568	0,12420330	0,15745150
Review Score	-	-	0,04814370	-0,03658929	-0,04704542
Score (Sent)	-	-	-	0,03489969	0,02844648
Price	-	-	-	-	0,05212215
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-11,77%	9,93%	12,42%	15,75%
Review Score	-	-	4,81%	-3,66%	-4,70%
Score (Sent)	-	-	-	3,49%	2,84%
Price	-	-	-	-	5,21%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 4,81% e assim não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho. E pontuamos a inversão da correlação entre as outras variáveis (Review Score x Price e Review Score x Review Help), porém de baixa intensidade.

4.4.1.3 Amostra com polaridade negativa

Correlação de Pearson em amostra com polaridade negativa (Tabela 16) do *marketplace* Amazon – análise inicial:

Tabela 16: Tabela de correlação de Pearson – Amostra negativa – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,05518685	0,08819398	0,18028610	0,21919290
Review Score	-	-	-0,03217707	0,09561335	-0,02392301
Score (Sent)	-	-	-	0,03478577	0,03628374
Price	-	-	-	-	0,05826910
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	5,52%	8,82%	18,03%	21,92%
Review Score	-	-	-3,22%	9,56%	-2,39%
Score (Sent)	-	-	-	3,48%	3,63%
Price	-	-	-	-	5,83%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como negativos pela análise de sentimentos feita por técnicas de *machine Learning* vemos o comportamento dissonante com as amostras positivas e negativas, destacamos como importante a correlação Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta -3,22% de correlação. Ainda que baixa, o sentido inverso e o valor mostram um comportamento distinto, indicando que a visão dos usuários difere de forma considerável (pela inversão do sinal) entre os dois.

Os demais comportamentos se mantêm relativamente estáveis, com alterações na intensidade, porém em sua grande maioria se mantem de baixa intensidade.

Correlação de Spearman em amostra com polaridade negativa (Tabela 17) do *marketplace* Amazon – análise inicial:

Tabela 17: Tabela de correlação de Spearman – Amostra negativa – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,03108560	-0,00109162	0,30112550	0,23678470
Review Score	-	-	0,09051213	0,08692172	-0,03263350
Score (Sent)	-	-	-	0,03960112	0,00351418
Price	-	-	-	-	0,09009540
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	3,11%	-0,11%	30,11%	23,68%
Review Score	-	-	9,05%	8,69%	-3,26%
Score (Sent)	-	-	-	3,96%	0,35%
Price	-	-	-	-	9,01%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Pela correlação de Spearman, a correlação de Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta o valor de 9,05%, um valor maior e de mesma intensidade, em relação a de Pearson. Também salientamos a correlação moderada que obtivemos no critério de classificação entre o preço e o número de caracteres.

Correlação de Kendall em amostra com polaridade negativa (Tabela 18) do *marketplace* Amazon – análise inicial:

Tabela 18: Tabela de correlação de Kendall – Amostra negativa – Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,02352136	-0,03501091	0,20388560	0,18376050
Review Score	-	-	0,06609916	0,06599679	-0,02812895
Score (Sent)	-	-	-	0,02639957	0,00264958
Price	-	-	-	-	0,07008889
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	2,35%	-3,50%	20,39%	18,38%
Review Score	-	-	6,61%	6,60%	-2,81%
Score (Sent)	-	-	-	2,64%	0,26%
Price	-	-	-	-	7,01%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 6,61% e assim não mostra força em sua correlação para ir contra a hipótese número 2 deste trabalho.


A fim de aprofundar um pouco nos indicativos obtidos pela análise das correlações estruturamos o boxplot (figura 4) para ilustrar a distribuição dos Scores objetivos frente ao resultado da análise de sentimento realizada pela inteligência artificial.

Observamos que há diversos usuários insatisfeitos que em sua crítica expressaram insatisfação e ainda assim marcaram na nota objetiva valores elevados. Essa distorção reforça e corrobora com nossa hipótese H2 evidenciando a importância da análise desse conteúdo.

Creemos que esta distorção pode ser efeito de insatisfações com outros pacotes do serviço que não o produto entregue, ou vice-versa, e que são expressos por cada usuário em suas avaliações. Além do capital econômico escondido nestas críticas que podem colaborar com a melhoria dos processos empresariais, temos o *e-WoM* se proliferando e podendo agir de forma negativa junto as bases de cliente sem a percepção da empresa que passa a acreditar que as notas positivas indicam um cenário de excelência frente a sua rede de consumidores.

Boxplot (Figura 4) com a distribuição dos scores versus a análise de sentimento efetuada:

Figura 4: Boxplot de distribuição de Score Objetivo X Análise de Sentimentos



Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por score de avaliação (Tabela 19):

Tabela 19: Tabela de quantidade média de caracteres por score objetivo.

`review/score`	`mean(Charcount)`
1	324
2	400
3	404
4	408
5	306

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por segmentação da análise de sentimentos (Tabela 20):


Tabela 20: Tabela de quantidade média de caracteres por classificação da análise de sentimentos.

Sentiment	`mean(Charcount)`
Negative	404
Neutral	180
Positive	198

Fonte: Elaboração própria.

Gráfico de quantidade por *reviews* objetivos (Figura 5):


Figura 5: Gráfico de Barras de quantidade de Reviews por Score.



Fonte: Elaboração própria.

Gráfico de quantidade por *reviews* de sentimentos (Figura 6):

Figura 6: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.



Fonte: Elaboração própria.

Aqui observamos um ponto interessante que difere da literatura e comumente observado, de acordo com os estudos de Zhang e Vásques (2014) e (Resnick, Zeckhauser, Firedman & Kuwabara, 2000) que estes sistemas reputacionais tendem a receber um volume maior de notas positivas, porém ao compararmos com o real sentimento expressado pelos usuários, vemos que isto difere, comprovando a hipótese H2 deste trabalho.

4.4.1.4 Regressões lineares múltiplas

Tabela 21: Regressão linear feita no software R – variável dependente Review Score – Amazon.

Modelo	B	Std. Error	T	Sig (p-value)
(Intercept)	3,08E+03	1,56E+01	197.638	< 2e-16 ***
Charcount	1,57E-01	1,93E-02	8.109	5.29e-16 ***
Sentiment N	2,83E+02	4,89E+00	57.868	< 2e-16 ***
Review Help	-1,39E+02	1,76E+01	-7.922	2.41e-15 ***

Variável dependente: Review/Score

Residuais			
Min	1Q	Median	Max
-37.386	-13.348	0.4906	17.699

Fonte: Elaboração própria.

Ao analisarmos a regressão multipla das variaveis (Tabela 21), sobre a variável dependente Review/Score, observamos que a a variável Review Help é a que menos colabora com a variável dependente, ainda que significamente relacionada, é em sentido oposto a esta.

Quanto as demais observamos que a que mais exerce influência é a variável Sentiment N, apresentando um valor positivo de 2,83E+02, em notação científica, e apresentando um valor significativo de p-value de <2e-16., significando um grau de confiança de 95% e assim corroborando com os achados nas demais análises de que a percepção dos consumidores, originada pela análise de sentimento através do *machine learning*, se relaciona com o review score analisado, indo em direção a confirmação da Hipotese H2 deste trabalho.

4.4.2 Amostra Bestbuy

4.4.2.1 Amostra com polaridade neutra

Correlação de Pearson em amostra com polaridade neutra (Tabela 22) do *marketplace* Bestbuy – análise inicial:

Tabela 22: de correlação de Pearson – Amostra neutra – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,01641584	-0,07705002
Review Score	-	-	-0,00122915
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	1,64%	-7,71%
Review Score	-	-	-0,12%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Para os comentários definidos como Neutros pela análise de sentimentos vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de *UGC*). Vemos que a correlação entre os dois de -0,12% se apresenta como baixa, praticamente nula, e de sentido oposto, indicando uma correlação inexistente entre os dois ou não linear. Isto mantém coerência com o que foi observado na plataforma da Amazon.

Adicionalmente podemos observar correlações de intensidade baixa a moderada entre o número de caracteres (Nº de Char) e o Review Score, de 1,64%, sendo praticamente nula e entre o Score(Sente), avaliação subjetiva, de -7,71%, baixa e em sentido oposto.

Correlação de Spearman em amostra com polaridade neutra (Tabela 23) do *marketplace* Bestbuy – análise inicial:

Tabela 23: Tabela de correlação de Spearman – Amostra neutra – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,03345303	-0,09032149
Review Score	-	-	0,01640182
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	3,35%	-9,03%
Review Score	-	-	1,64%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela análise não linear, observamos a correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de *UGC*), correlação

de 1,64% frente a 9,05% da Amazon. Uma queda considerável entre a relação das duas. Aqui temos que a correlação entre os dois se mantém baixa, mesmo na avaliação não linear, porém de mesmo sentido, corroborando para a confirmação da hipótese H2 deste trabalho.

Correlação de Kendall em amostra com polaridade neutra (Tabela 24) do *marketplace* Bestbuy – análise inicial:

Tabela 24: Tabela de correlação de Kendall – Amostra neutra – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,02675083	-0,06007408
Review Score	-	-	0,01267241
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	2,68%	-6,01%
Review Score	-	-	1,27%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Aqui temos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 1,27% contra 6,61% da Amazon e assim não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho.

4.4.2.2 Amostra com polaridade positiva

Correlação de Pearson em amostra com polaridade positiva (Tabela 25) do *marketplace* Bestbuy – análise inicial:

Tabela 25: Tabela de correlação de Pearson – Amostra positiva – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,04695665	0,1446914
Review Score	-	-	0,07417945
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-4,70%	14,47%
Review Score	-	-	7,42%
Score (Sent)	-	-	-

Fonte: Elaboração própria

Ao separarmos a amostra com os comentários definidos como Positivos pela análise de sentimentos feita vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta 7,42% frente a 8,76% de correlação da base da Amazon. Vemos que a correlação entre os dois se apresenta como baixa, indicando uma correlação fraca entre os dois ou não linear.

Adicionalmente podemos observar correlações de intensidade baixa a moderada entre o número de caracteres (Nº de Char) e o Review Score, de -4,70% frente a 1,64% da amostra neutra, sendo praticamente nula e entre o Score(Sente), avaliação subjetiva, de 14,47%, mais forte e em direção oposta a amostra neutra que apresentou -7,71%.

Observamos que há uma variação interessante frente a amostra neutra, que indica um maior engajamento da comunidade na leitura de comentários positivos frente aos neutros e que a avaliação retratada na nota objetiva parece não apresentar muita ligação com o texto produzido pelos usuários, indicativo de nossa hipótese H2.

Correlação de Spearman em amostra com polaridade positiva (Tabela 26) do *marketplace* Bestbuy – análise inicial:

Tabela 26: Tabela de correlação de Spearman– Amostra positiva – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,01521225	0,1429167
Review Score	-	-	0,05704250
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-1,52%	14,29%
Review Score	-	-	5,70%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Por Spearman, a correlação de Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta o valor de 5,70% frente a 6,16% da base da Amazon, um valor ainda menor do que o obtido na correlação linear de Pearson.

Correlação de Kendall em amostra com polaridade positiva (Tabela 27) do marketplace Bestbuy – análise inicial:

Tabela 27: Tabela de correlação de Kendall – Amostra positiva – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,01238372	0,09625287
Review Score	-	-	0,04628641
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-1,24%	9,63%
Review Score	-	-	4,63%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 4,63% frente a 4,81% da base da Amazon, mostrando um comportamento semelhante entre as empresas e não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho.

4.4.2.3 Amostra com polaridade negativa

Correlação de Pearson em amostra com polaridade negativa (Tabela 28) do marketplace Bestbuy – análise inicial:

Tabela 28: Tabela de correlação de Pearson – Amostra negativa – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,02820325	0,1203659
Review Score	-	-	-0,03408432
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-2,82%	12,04%
Review Score	-	-	-3,41%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como negativos vemos o comportamento dissonante com as amostras positivas e neutras, destacamos como importante a correlação Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresentando aqui -3,41% frente a -3,22% da base da Amazon. Ainda que baixa, o sentido inverso e o valor mostram um comportamento distinto, indicando que a visão dos usuários difere de forma considerável (pela inversão do sinal) entre os dois e que o comportamento é observado em ambas as bases de dados.

Correlação de Spearman em amostra com polaridade negativa (Tabela 29) do *marketplace* Bestbuy – análise inicial:

Tabela 29: Tabela de correlação de Spearman – Amostra negativa – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,06628967	-0,3637343
Review Score	-	-	0,12344650
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-6,63%	-36,37%
Review Score	-	-	12,34%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela correlação de Spearman, para o Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresentamos o valor de 12,34% frente a 9,05% da Amazon, um valor maior e de mesma intensidade, em relação a de Pearson. O que reforça o comportamento semelhante entre elas.

Correlação de Kendall em amostra com polaridade negativa (Tabela 30) do *marketplace* Bestbuy – análise inicial:

Tabela 30: Tabela de correlação de Kendall – Amostra negativa – Bestbuy

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,05183143	-0,263004
Review Score	-	-	0,09547252
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-5,18%	-26,30%
Review Score	-	-	9,55%
Score (Sent)	-	-	-

Fonte: Elaboração própria.


Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 9,55% frente a 6,61% da base da Amazon, e assim não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho.

Para uma visão mais profunda do comportamento destas bases estruturamos o gráfico (Figura 8) para ilustrar a distribuição dos *Scores* objetivos frente ao resultado da análise de sentimento realizada pela inteligência artificial.

Observamos novamente que há diversos usuários insatisfeitos que em suas críticas expressaram insatisfação e ainda assim marcaram na nota objetiva valores elevados. Essa distorção reforça e corrobora com nossa hipótese H2 evidenciando a importância da análise desse conteúdo, além de se mostrar presente e constante nas bases americanas observadas.

Creemos que esta distorção pode ser efeito de insatisfações com outros pacotes do serviço que não o produto entregue, ou vice-versa, e que são expressos por cada usuário em suas avaliações. Além do capital econômico escondido nestas críticas que podem colaborar com a melhoria dos processos empresariais, temos o *e-WoM* se proliferando e podendo agir de forma negativa junto as bases de cliente sem a percepção da empresa que passa a acreditar que as notas positivas indicam um cenário de excelência frente a sua rede de consumidores.

Boxplot (Figura 7) com a distribuição dos *scores versus* a análise de sentimento efetuada:

Figura 7: Boxplot de distribuição de Score Objetivo X Análise de Sentimentos

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por score de avaliação (tabela 31):

Tabela 31: Tabela de quantidade média de caracteres por score objetivo.

<code>`review/score`</code>	<code>`mean(Charcount)`</code>
1	208
2	201
3	152
4	143
5	120

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por segmentação da análise de sentimentos (Tabela 32):


Tabela 32: Tabela de quantidade média de caracteres por classificação da análise de sentimentos

Sentiment	`mean(Charcount)`
Negative	199
Neutral	106
Positive	97

Fonte: Elaboração própria.


Gráfico de quantidade de reviews objetivos (Figura 8):

Figura 8: Gráfico de Barras de quantidade de Reviews por Score.



Fonte: Elaboração própria.

Gráfico de quantidade de reviews por análise de sentimentos (Figura 9):

Figura 9: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.

Fonte: Elaboração própria.

4.4.2.4 Regressões lineares múltiplas

Tabela 33: Regressão linear feita no software R – variável dependente review.rating – Bestbuy.

Modelo	B	Std. Error	T	Sig (p-value)
(Intercept)	4.217e+00	1.481e-02	284.673	< 2e-16 ***
Charcount	-1.669e-04	3.714e-05	-4.494	7.03e-06 ***
Sentiment N	1.031e-01	3.289e-03	31.365	< 2e-16 ***
Review Help	2.798e-03	1.355e-03	2.065	0.039 *
Variável dependente: reviews.rating				
Residuais				
Min	1Q	Median	3Q	Max
-3.7261	-0.3100	0.2770	0.3127	1.1567

Fonte: Elaboração própria.

Ao analisarmos a regressão multipla das variaveis (Tabela 33), sobre a variável dependente Review/Score, observamos que a a variável Charcount (Número de caracteres) é sgnificamente relacionada a variavel dependente, porém de relacionamento oposto, significando que quanto maior a avaliação dos consumidores, menor é a quantidade de caracteres empregada. Corroborando com os achados anteriores.

Observamos também que a variável Review Help é a que menos se relaciona por expressar um valor de significancia baixo em relação aos demais.

Quanto a variável Sentiment N (que expressa o indicador da análise de sentimento gerada por *machine learning*), esta apresenta um valor positivo de 1,031e-03, em notação científica, e um valor significativo de p-value de $<2e-16$, significando um grau de confiança maior que 95% e assim corroborando com os achados nas demais análises de que a percepção dos consumidores, originada pela análise de sentimento através do *machine learning*, se relaciona com o review score analisado, indo em direção a confirmação da Hipotese H2 deste trabalho.

4.4.3 Amostra ToyRus

4.4.3.1 Amostra com polaridade neutra

Correlação de Pearson em amostra com polaridade neutra (Tabela 34) do *marketplace* ToyRus – análise inicial:

Tabela 34: Tabela de correlação de Pearson – Amostra neutra – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,00324721	-0,05612087
Review Score	-	-	-0,00014003
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,32%	-5,61%
Review Score	-	-	-0,01%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Para os comentários definidos como Neutros pela análise de sentimentos vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC). Vemos que a correlação entre os dois de $-0,01\%$, frente $0,12\%$ da BestBuy e assim se apresenta como baixa, praticamente nula, e de sentido oposto, indicando uma correlação inexistente entre os dois ou não linear. Isto mantém coerência com o que foi observado na plataforma da Amazon.

Adicionalmente podemos observar correlações de intensidade baixa a moderada entre o número de caracteres (Nº de Char) e o Review Score, de 0,32% frente a 1,64% da Bestbuy, sendo praticamente nula e entre o Score(Sente), avaliação subjetiva, de -5,61% frente a -7,71% da Bestbuy, baixa e em sentido oposto.

Correlação de Spearman em amostra com polaridade neutra (Tabela 35) do *marketplace* ToyRus – análise inicial:

Tabela 35: Tabela de correlação de Spearman – Amostra neutra – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,02163568	-0,09047467
Review Score	-	-	-0,00481166
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	2,16%	-9,05%
Review Score	-	-	-0,48%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela análise não linear, observamos a correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), correlação de -0,48% frente a 1,64% da Bestbuy e a 9,05% da Amazon. Uma queda considerável entre a relação das duas. Aqui temos que a correlação entre os dois se mantém baixa, mesmo na avaliação não linear, porém de mesmo sentido, corroborando para a confirmação da hipótese H2 deste trabalho.

Correlação de Kendall em amostra com polaridade neutra (Tabela 36) do *marketplace* ToyRus – análise inicial:

Tabela 36: Tabela de correlação de Kendall – Amostra neutra – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	0,01776604	-0,06100728
Review Score	-	-	-0,00435970
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	1,78%	-6,10%
Review Score	-	-	-0,44%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Aqui temos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando -0,44% frente a 1,27% da Bestbuy e 6,61% da Amazon e assim não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho.

4.4.3.2 Amostra com polaridade positiva

Correlação de Pearson em amostra com polaridade positiva (Tabela 37) do *marketplace* ToyRus – análise inicial:

Tabela 37: Tabela de correlação de Pearson – Amostra positiva – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,02378939	0,17959180
Review Score	-	-	0,09741732
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-2,38%	17,96%
Review Score	-	-	9,74%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como Positivos pela análise de sentimentos feita vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta 9,74% frente a 7,42% da Bestbuy e a 8,76% de correlação da

base da Amazon. Vemos que a correlação entre os dois indicadores se apresenta como baixa, indicando uma correlação fraca entre os dois ou não linear, e constante entre as bases americanas.

Adicionalmente pode-se observar as correlações de intensidade baixa a moderada entre as variáveis número de caracteres (Nº de Char) e o Review Score, de -2,38% frente a -4,70% da Bestbuy, sendo praticamente nula e entre o Score(Sente), avaliação subjetiva, de 17,96% frente a 14,47% da Bestbuy, mais forte e em direção oposta a amostra neutra que apresentou -5,61%.

Observamos que há uma variação interessante frente a amostra neutra, que indica um maior engajamento da comunidade na leitura de comentários positivos frente aos neutros e que a avaliação retratada na nota objetiva parece não apresentar muita ligação com o texto produzido pelos usuários, indicativo de nossa hipótese H2.

Correlação de Spearman em amostra com polaridade positiva (Tabela 38) do *marketplace* ToyRus – análise inicial:

Tabela 38: Tabela de correlação de Spearman – Amostra positiva – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,01894208	0,20938890
Review Score	-	-	0,06038157
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-1,89%	20,94%
Review Score	-	-	6,04%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Por Spearman, a correlação de Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresenta o valor de 6,04% enquanto na Bestbuy de 5,70% frente a 6,16% da base da Amazon, um valor ainda menor do que o obtido na correlação linear de Pearson, porém constante entre as bases americanas.

Correlação de Kendall em amostra com polaridade positiva (Tabela 39) do *marketplace* ToyRus – análise inicial:

Tabela 39: Tabela de correlação de Kendall – Amostra positiva – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,01520028	0,14298690
Review Score	-	-	0,04891229
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-1,52%	14,30%
Review Score	-	-	4,89%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 4,89%, enquanto na Bestbuy 4,63% e 4,81% da base da Amazon, mostrando um comportamento semelhante entre as empresas e não mostra força em sua correlação para ir contra a hipótese H2 deste trabalho.

4.4.3.3 Amostra com polaridade negativa

Correlação de Pearson em amostra com polaridade negativa (Tabela 40) do *marketplace* ToyRus – análise inicial:

Tabela 40: Tabela de correlação de Pearson – Amostra negativa – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,05935570	0,12444000
Review Score	-	-	-0,01266697
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-5,94%	12,44%
Review Score	-	-	-1,27%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como Negativos vemos o comportamento dissonante com as amostras positivas e neutras, destacamos como importante a correlação Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do

usuário por intermédio de UGC), apresentando aqui -1,27%, enquanto na Bestbuy de -3,41% e -3,22% da base da Amazon.

Ainda que baixa, o sentido inverso e o valor mostram um comportamento distinto, indicando que a visão dos usuários difere de forma considerável (pela inversão do sinal) entre os dois e que o comportamento é observado nas três bases de dados americanas.

Correlação de Spearman em amostra com polaridade negativa (Tabela 41) do *marketplace* ToyRus – análise inicial:

Tabela 41: Tabela de correlação de Spearman – Amostra negativa – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,06156982	-0,42906650
Review Score	-	-	0,18316820
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-6,16%	-42,91%
Review Score	-	-	18,32%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela correlação de Spearman, para o Review Score (nota objetiva da avaliação) e Score (sent) – (avaliação subjetiva do usuário por intermédio de UGC), apresentamos o valor de 18,32%, para Bestbuy de 12,34% frente a 9,05% da Amazon, um valor maior e de mesma intensidade, em relação a de Pearson. O que reforça o comportamento semelhante entre elas.

Correlação de Kendall em amostra com polaridade negativa (Tabela 42) do *marketplace* ToyRus – análise inicial:

Tabela 42: Tabela de correlação de Kendall – Amostra negativa – ToyRus

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-0,04726135	-0,30045520
Review Score	-	-	0,14125020
Score (Sent)	-	-	-

	Nº de Char	Review Score	Score (Sent)
Nº de Char	-	-4,73%	-30,05%
Review Score	-	-	14,13%
Score (Sent)	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Score(Sent), avaliações objetivas e subjetivas, apresentando 14,13% enquanto na Bestbuy de 9,55% frente a 6,61% da base da Amazon, ainda que mostre um valor baixo a moderado de correlação frente aos valores baixos das outras bases, a força e o sentido observado não apresenta força em sua correlação para ir contra a hipótese H2 deste trabalho.


Para uma visão mais profunda do comportamento destas bases estruturamos o gráfico (Figura 11) para ilustrar a distribuição dos Scores objetivos frente ao resultado da análise de sentimento realizada pela inteligência artificial.

Observamos novamente que há diversos usuários insatisfeitos que em sua crítica expressaram insatisfação e ainda assim marcaram na nota objetiva valores elevados. Essa distorção reforça e corrobora com nossa hipótese H2 evidenciando a importância da análise desse conteúdo, além de se mostrar presente e constante nas bases americanas observadas.

Creemos que esta distorção pode ser efeito de insatisfações com outros pacotes do serviço que não o produto entregue, ou vice-versa, e que são expressos por cada usuário em suas avaliações.

Além do capital econômico escondido nestas críticas que podem colaborar com a melhoria dos processos empresariais, temos o e-WoM se proliferando e podendo agir de forma negativa junto as bases de cliente sem a percepção da empresa que passa a acreditar que as notas positivas indicam um cenário de excelência frente a sua rede de consumidores.

Boxplot (Figura 10) com a distribuição dos *scores versus* a análise de sentimento efetuada:

Figura 10: Boxplot de distribuição de Score Objetivo X Análise de Sentimentos

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por score de avaliação (Tabela 43):

Tabela 43: Tabela de quantidade média de caracteres por score objetivo.

<code>`review/score`</code>	<code>`mean(Charcount)`</code>
1	180
2	207
3	133
4	131
5	111

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por segmentação da análise de sentimentos (Tabela 44):


Tabela 44: Tabela de quantidade média de caracteres por classificação da análise de sentimentos.

Sentiment	`mean(Charcount)`
Negative	177
Neutral	105
Positive	97

Fonte: Elaboração própria.

Gráfico de quantidade de reviews objetivos (Figura 11):


Figura 11: Gráfico de Barras de quantidade de Reviews por Score.



Fonte: Elaboração própria.

Gráfico de quantidade de reviews por sentimentos (Figura 12):

Figura 12: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.



Fonte: Elaboração própria.

4.4.3.4 Regressões lineares múltiplas

Tabela 45: Regressão linear feita no software R – variável dependente review.rating – ToyRus.

Modelo	B	Std. Error	T	Sig (p-value)
(Intercept)	4.0487290	0.0556724	72.724	<2e-16 ***
Charcount	-0.0003240	0.0001921	-1.686	0.0919 .
Sentiment N	0.1427521	0.0110987	12.862	<2e-16 ***
Review Help	-0.0170583	0.0135745	-1.257	0.2091

Variável dependente: reviews.rating

Residuais				
Min	1Q	Median	3Q	Max
-3.7489	-0.4239	0.2573	0.3007	1.2236

Fonte: Elaboração própria.

Ao analisarmos a regressão múltipla das variáveis (Tabela 45), sobre a variável dependente reviews.rating, observamos que a variável Charcount (Número de caracteres) apresenta um relacionamento de sentido oposto, significando que quanto maior a avaliação dos consumidores, menor é a quantidade de caracteres empregada, porém apresentando um grau de confiança menor que 95%.

Para a variável Review Help vemos que esta apresenta um grau de confiança ainda menor e de sentido oposto a variável dependente, não colaborando muito ao review.rating.

Quanto a variável Sentiment N (que expressa o indicador da análise de sentimento gerada por *machine learning*), esta apresenta um valor positivo de 0.14275,21, em notação científica, e um valor significativo de p-value de $<2e-16$, significando um grau de confiança maior que 95% e assim corroborando com os achados nas demais análises de que a percepção dos consumidores, originada pela análise de sentimento através do *machine learning*, se relaciona com o review score analisado, indo em direção a confirmação da Hipotese H2 deste trabalho.

4.4.4 Amostra Olist (BR)

4.4.4.1 Amostra completa

Correlação de Pearson em amostra completa, (Tabela 46), do *marketplace* Olist:

Tabela 46: Tabela de correlação de Pearson – Amostra completa – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,37965590	0,05104235
Review Score	-	-	-0,01481645
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-37,97%	5,10%
Review Score	-	-	-1,48%
Order Price	-	-	-

Fonte: Elaboração própria.

Dos pontos que corroboram a visão de impacto relativo entre os componentes do *crowdvoting* podemos observar que apresenta baixa a moderada correlação é o número de caracteres – indicando um aumento ou incentivo ao uso de argumentos subjetivos – em produtos de maior preço (Nº de Char x Order Price), com valor de 5,10%. Corrobora com a literatura discutida anteriormente de processo decisório de compra com os pontos de insatisfação e satisfação exercendo influência no consumidor.

Nos pontos adicionais para a correlação de Pearson observamos correlações de baixa intensidade entre Review Score x Order Price, apresentando -1,48%, indicando que atuam de formas opostas, porém de correlação muito baixa, próxima a nulidade.

O ponto de destaque também é a força observada entre o Review Score (análise objetiva) e o número de caracteres (Review Score x N° de Char), que apresentou valor de -37,97%, correlação de intensidade moderada a alta para estudos humanos, e que mostra que a disposição do usuário em dispendar tempo para deixar sua análise é de intensidade moderada e sentido oposto ao Review Score. Isto apoia a literatura atual do *e-WoM*, como discutido anteriormente.

Correlação de Spearman em amostra completa (Tabela 47) do *marketplace* Olist:

Tabela 47: Tabela de correlação de Spearman – Amostra completa – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,34709120	0,05269730
Review Score	-	-	-0,00516199
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-34,71%	5,27%
Review Score	-	-	-0,52%
Order Price	-	-	-

Fonte: Elaboração própria.

Por Spearman, por sua característica de explorar as relações de forma linear e não linear observamos que o efeito observado pela correlação de Pearson se intensifica e para algumas variáveis toma sentido oposto, valor negativo de correlação.

Temos assim a intensificação das correlações de número de caracteres contra preço e auxílio da crítica subjetiva (Nº de Char x Order Price, Nº de Char x Review Score), sendo a primeira de 5,27% e a segunda de -34,71%. Observamos um comportamento similar a análise de Pearson discutida anteriormente

Este ponto nos leva a crer a confirmação da teoria do *e-WoM* da forma como se dá destaque na literatura (Christodoulides et al, 2012; Grégoire et al, 2014), que avaliações de insatisfação contam com maior esforço de disseminação desta informação por parte do consumidor.

Correlação de Kendall em amostra completa (Tabela 48) do *marketplace* Olist:

Tabela 48: Tabela de correlação de Kendall – Amostra completa – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,26203720	0,03539889
Review Score	-	-	-0,00388822
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-26,20%	3,54%
Review Score	-	-	-0,39%
Order Price	-	-	-

Fonte: Elaboração própria.

Para a consideração das correlações de Kendall, uma vez que sua finalidade é analisar a correlação de dois termos frente a sua classificação temos a partir desta visão uma correlação baixa entre a estrutura de classificação destas duas variáveis (Review Score x Order Price) de 0,39%, e da correlação entre número de caracteres e preço (Nº de Char x Order Price) de 3,54% ainda que busquem demonstrar o mesmo posicionamento, indicando classificações distintas.

4.4.4.2 Amostra com polaridade neutra

Correlação de Pearson em amostra com polaridade neutra (Tabela 49) do *marketplace* Olist – análise inicial:

Tabela 49: Tabela de correlação de Pearson – Amostra neutra – Olist

	Nº de Char	Order Price
Nº de Char	-	0,05221699
Order Price	0,05221699	-

	Nº de Char	Order Price
Nº de Char	-	5,22%
Order Price	5,22%	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como Neutros pela análise de sentimentos feita por técnicas de *machine Learning* vemos o comportamento dissonante importante na correlação entre Review Score (nota objetiva da avaliação) e Score (*sent*) – (avaliação subjetiva do usuário por intermédio de UGC). Vemos que a correlação entre os dois se apresenta como baixa e de sentido oposto, indicando uma correlação inexistente entre os dois ou não linear.

Adicionalmente podemos observar correlações de intensidade baixa entre o número de caracteres (Nº de Char) e Preço (*Price*), correlação de 5,22% frente a 5,10% da amostra total, expressando para aqueles usuários que deram notas intermediárias, ou seja, expressam insatisfações latentes ao serviço/produto, mas que dispenderam um valor maior na sua compra, sentem maior necessidade de expressar a sua frustração e assim caminham a teoria do *e-WoM*, porém é interessante ressaltar que estes comentários ainda não são vistos como negativo pelo *score* objetivo, o que nos leva a reforçar a hipótese de que o *score* objetivo não reflete bem a realidade como o subjetivo (Hipótese H2 desta tese).

Correlação de Spearman em amostra com polaridade neutra (Tabela 50) do *marketplace* Olist – análise inicial:

Tabela 50: Tabela de correlação de Spearman – Amostra neutra – Olist

	Nº de Char	Order Price
Nº de Char	-	0,04455689
Order Price	0,04455689	-

	Nº de Char	Order Price
Nº de Char	-	4,46%
Order Price	4,46%	-

Fonte: Elaboração própria.

Observando ainda a correlação entre o Nº de Char x Order Price por Spearman vemos um retorno a 4,46%, em consonância a amostra geral, para uma visão não linear destes.

Correlação de Kendall em amostra com polaridade neutra (Tabela 51) do *marketplace* Olist – análise inicial:

Tabela 51: Tabela de correlação de Kendall– Amostra neutra – Olist

	Nº de Char	Order Price
Nº de Char	-	0,02980965
Order Price	0,02980965	-

	Nº de Char	Order Price
Nº de Char	-	2,98%
Order Price	2,98%	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Nº de Char x Order Price, apresentando 2,98%, mostrando correlação baixa a nula, no formato de classificação entre elas.

4.4.4.3 Amostra com polaridade positiva

Correlação de Pearson em amostra com polaridade positiva (Tabela 52) do *marketplace* Olist – análise inicial:

Tabela 52: Tabela de correlação de Pearson – Amostra positiva – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,09217890	0,05706380
Review Score	-	-	0,01133781
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-9,22%	5,71%
Review Score	-	-	1,13%
Order Price	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como Positivos pela análise de sentimentos feita por técnicas de *machine Learning* vemos na correlação entre Review Score (nota objetiva da avaliação) e Nº de Char (número de caracteres) um valor de -9,22% frente a -

37,96% da amostra completa. Isso indica uma direção do comportamento do usuário brasileiro que para notas positivas tende a dedicar menos esforço na escrita de comentários, em consonância ao *e-WoM* da literatura (Jansen, 2009; Ghose & Ipeirotis, 2011).

Adicionalmente podemos observar correlações de intensidade baixa a moderada entre o número de caracteres (Nº de Char) e Preço (Order Price), correlação de 5,71% frente a base completa de 5,10%, valores muito próximos.

Observamos que há uma variação interessante frente a amostra neutra, que indica um maior engajamento da comunidade na leitura de comentários neutros frente aos positivos, diferente do observado nas bases americanas.

Correlação de Spearman em amostra com polaridade positiva (Tabela 53) do *marketplace* Olist – análise inicial:

Tabela 53: Tabela de correlação de Spearman – Amostra positiva – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,05741830	0,05762929
Review Score	-	-	0,00961321
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-5,74%	5,76%
Review Score	-	-	0,96%
Order Price	-	-	-

Fonte: Elaboração própria.

Por Spearman, a correlação de Review Score (nota objetiva da avaliação) e Order Price – (Preço do pedido), apresenta o valor de 0,96%, enquanto na amostra integral obtivemos um valor de -0,52%. Ambos muito próximos da nulidade, porém com intensidade oposta.

Também salientamos a inversão da correlação entre a variável de preço (Price) e a número de caracteres (Nº de Char), com um valor de 5,76% enquanto na amostra integral 3,54%, valores baixos e próximos e frente a número de caracteres e o Score objetivo (N mostrando uma correlação baixa, de Char x Review Score) um valor de -5,74% enquanto na amostra integral de -26,20%. Aqui observamos o mesmo sentido, porém intensidades

diferentes, indicando que a intensidade de escrita dos comentários positivos frente a média da base integral, é maior.

Correlação de Kendall em amostra com polaridade positiva (Tabela 54) do *marketplace* Olist – análise inicial:

Tabela 54: Tabela de correlação de Kendall – Amostra positiva – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,04713365	0,03876160
Review Score	-	-	0,00786479
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-4,71%	3,88%
Review Score	-	-	0,79%
Order Price	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre a análise objetiva e o preço do pedido (Review Score X Order Price) de 0,79% enquanto na base completa obtivemos 0,39%, valores baixos e próximos.

Para a relação entre o número de caracteres e as demais variáveis obtivemos (Nº de Char x Review Score) de -4,71% enquanto na base completa -26,20%, mesmo sentido mas intensidade diferente representativa, e para número de caracteres versus Preço (Nº de Char x Order Price) um resultado de 3,88% contra 3,54% da amostra completa, valores praticamente iguais.

4.4.4.4 Amostra com polaridade negativa

Correlação de Pearson em amostra com polaridade negativa (Tabela 55) do *marketplace* Olist – análise inicial:

Tabela 55: Tabela de correlação de Pearson – Amostra negativa – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,02868106	0,03944996
Review Score	-	-	-0,29250160
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-2,87%	3,94%
Review Score	-	-	-29,25%
Order Price	-	-	-

Fonte: Elaboração própria.

Ao separarmos a amostra com os comentários definidos como negativos vemos o comportamento dissonante com as amostras positivas e negativas, destacamos como importante a correlação Review Score (nota objetiva da avaliação) e número de caracteres (Nº de Char), que apresenta -2,87% enquanto na amostra positiva -9,22% e na amostra integral -37,97%.

Para a correlação de número de caracteres e preço (Nº de Char x Order Price) temos 3,94% na amostra negativa, 5,71% na amostra positiva e 5,10% na amostra integral. Enquanto para análise objetiva e preço (Review Score x Order Price) temos -29,25% na amostra negativa, 1,13% na amostra positiva e -1,48% na amostra completa.

Para esta última destacamos a dissonância do comportamento, onde o preço do produto aparenta apresentar um efeito oposto a avaliação objetiva principalmente quanto a percepção da compra foi negativa, mas se mostra indiferente quando positiva no comentário, mais uma vez mostrando que os efeitos no processo de compra e no e-WoM acompanham a literatura, porém apresenta uma diferença importante frente aos valores observados na empresa *Amazon*.

Correlação de Spearman em amostra com polaridade negativa (Tabela 56) do *marketplace* Olist – análise inicial:

Tabela 56: Tabela de correlação de Spearman– Amostra negativa – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,02790930	0,05122261
Review Score	-	-	-0,02436966
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-2,79%	5,12%
Review Score	-	-	-2,44%
Order Price	-	-	-

Fonte: Elaboração própria.

Pela correlação de Spearman, o Review Score (nota objetiva da avaliação) e Preço (Order Price) apresenta o valor de -2,44% enquanto na amostra positiva 0,96% e na amostra integral de 0,52%. Para a correlação de Review Score x Nº de Char observamos um valor de -2,79% enquanto na amostra positiva -5,74%, e na amostra integral de -34,71%.

Correlação de Kendall em amostra com polaridade negativa (Tabela 57) do *marketplace* Olist – análise inicial:

Tabela 57: Tabela de correlação de Kendall – Amostra negativa – Olist

	Nº de Char	Review Score	Order Price
Nº de Char	-	-0,02286392	0,03445718
Review Score	-	-	-0,01993462
Order Price	-	-	-

	Nº de Char	Review Score	Order Price
Nº de Char	-	-2,29%	3,45%
Review Score	-	-	-1,99%
Order Price	-	-	-

Fonte: Elaboração própria.

Pela análise de Kendall, no critério de correlação das classificações, destacamos a baixa correlação entre Review Score e Order Price, um valor de -1,99%, enquanto na positiva de 0,79% e na integral de -0,39%.

Para a correlação de Review Score e N° de Char temos -2,29% para a amostra negativa, -4,71% para a amostra positiva e -26,20% para a amostra integral. Pontos que nos levam a crer que a divergência no engajamento e classificação para a empresa brasileira se situe entre os comentários avaliados como razoáveis.


A fim de aprofundar um pouco nos indicativos obtidos pela análise das correlações estruturamos o gráfico (Figura 14) para ilustrar a distribuição dos *Scores* objetivos frente ao resultado da análise de sentimento realizada pela inteligência artificial.

Observamos que há diversos usuários insatisfeitos que em sua crítica expressaram insatisfação e ainda assim marcaram na nota objetiva valores elevados. Essa distorção reforça e corrobora com nossa hipótese H2 evidenciando a importância da análise desse conteúdo.

Também observamos que a análise de sentimento realizada por *machine learning*, para a base brasileira se adequou bem, principalmente relativo aos comentários positivos e neutros, mas expôs que a mesma divergência observada nas bases americanas entre os critérios objetivos e subjetivos de avaliação.

Creemos que esta distorção pode ser efeito de insatisfações com outros pacotes do serviço e não o produto entregue, ou vice-versa, e que são expressos por cada usuário em suas avaliações. Além do capital econômico escondido nestas críticas que podem colaborar com a melhoria dos processos empresariais, temos o e-WoM se proliferando e podendo agir de forma negativa junto as bases de cliente sem a percepção da empresa que passa a acreditar que as notas positivas indicam um cenário de excelência frente a sua rede de consumidores.

Boxplot (Figura 13) com a distribuição dos *scores* versus a análise de sentimento efetuada:

Figura 13: Boxplot de distribuição de Score Objetivo X Análise de Sentimentos

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por score de avaliação (Tabela 58):

Tabela 58: Tabela de quantidade média de caracteres por score objetivo.

<code>`review/score`</code>	<code>`mean(Charcount)`</code>
1	87
2	82
3	70
4	53
5	45

Fonte: Elaboração própria.

Média de caracteres utilizados nos comentários subjetivos por segmentação da análise de sentimentos (Tabela 59):


Tabela 59: Tabela de quantidade média de caracteres por classificação da análise de sentimentos.

Sentiment	`mean(Charcount)`
Negative	84
Neutral	50
Positive	56

Fonte: Elaboração própria.

Distribuição de quantidades de Reviews objetivos (Figura 14):


Figura 14: Gráfico de Barras de quantidade de Reviews por Score.



Fonte: Elaboração própria.

Distribuição de quantidades de Reviews subjetivos (Figura 15):

Figura 15: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.



Fonte: Elaboração própria.

4.4.4.5 Regressões lineares múltiplas

Tabela 60: Regressão linear feita no software R – variável dependente Review/Score – Olist.

Modelo	B	Std. Error	T	Sig (p-value)
(Intercept)	3.279e+00	3.564e-02	91.995	< 2e-16 ***
ContChar	-1.157e-02	2.310e-04	-50.065	< 2e-16 ***
Sentiment N	2.891e-01	7.270e-03	39.759	< 2e-16 ***
Price 2	1.499e-06	5.011e-07	2.991	0.00278 **

Variável dependente: Review/Score

Residuais				
Min	1Q	Median	3Q	Max
-3.7663	-0.8185	0.4632	0.9523	3.5093

Fonte: Elaboração própria.

Ao analisarmos a regressão multipla das variaveis (Tabela 60), sobre a variável dependente Review/Score, observamos que a a variável Charcount (Número de caracteres) apresenta um valor de -1.157e-02, assim tendo um relacionamento de sentido oposto com a variável dependente analisada. Isto significa que quanto maior a avaliação dos consumidores, menor é a quantidade de caracteres empregada, e apresenta um grau de confiança menor que 95%.

Para a variável “Price 2” vemos que esta apresenta um grau de confiança menor que as demais e um valor de $1.499e-06$, sendo menos significativa que as demais, mas se relacionamento com a variável dependente em análise.

Quanto a variável Sentiment N (que expressa o indicador da análise de sentimento gerada por *machine learning*), esta apresenta um valor positivo de $2.891e-01$, em notação científica, e um valor significativo de p-value de $<2e-16$, significando um grau de confiança maior que 95% e assim corroborando com os achados nas demais análises de que a percepção dos consumidores, corroborando com a confirmação da hipótese H2 deste trabalho.

4.5 Análise e discussão dos resultados

Uma vez efetuadas as análises das bases pudemos triangular as bases americanas ao evidenciar que estas, mesmo com janelas de tempo, para a questão da percepção do usuário e seu engajamento com as plataformas, se comportam da mesma forma.

Observamos que entre a plataforma Amazon, Bestbuy e ToyRus, o relacionamento dos usuários ocorre de forma muito parecida pelas correlações realizadas, se diferenciando apenas no número de sentimentos negativos aos serviços/produtos ofertados quando filtrados pela análise de sentimento.

Entendemos esse achado como significativo, pois vai contra o posicionamento da literatura atual, que deriva as suas métricas a partir da avaliação do *score* objetivo dos produtos (a nota dada no *rating* de 1 a 5 estrelas do produto). A partir deste achado entendemos como relevante a aplicação de análise de sentimentos dentro destas plataformas, uma vez que dentro da teoria do consumidor discutida, bem como a construção de marcas e as influências no processo decisório do consumidor no momento da compra, a métrica para a apresentação de promoções, influencias de compra e desconto podem estar sendo aplicadas de forma incorreta, perdendo assim a sua eficácia frente aos diversos clientes da base.

Outro ponto é na ação detectiva e após compra frente a insatisfação de um consumidor a fim de controlar os efeitos danosos do *e-WoM*, a compreensão da insatisfação e dos pontos de melhoria destes a partir do comentários dados por esse – feedback de compra a partir do UGC suportado pela plataforma reputacional na estratégia de utilização de *crowdvoting* para construção de confiança e validação dos serviços – permite a atuação imediata e antes da percepção direta do usuário, uma vez que este por muitas vezes avalia como bom o serviço, porém expressa suas queixas de forma subjetiva.

Estes pontos respectivamente dão sustentação para a análise das hipóteses direcionadores deste estudo, conforme contextualizadas a seguir:

- ✓ H1 – *Crowdvoting* aumenta o engajamento e fidelização dos usuários a um varejo eletrônico.

Já é definido pela literatura que estruturas que fomentam rede e propiciam sistemas reputacionais são importantes na fidelização e aumento da segurança percebida por usuários na utilização de sistemas reputacionais (Resnick et al, 2006; Dellarocas 2003). Nosso estudo visou observar se a aplicação de estratégias de *crowdvoting* colaboram neste sentido ou se a sua aplicação gera entraves que pudessem desincentivar o reforço destas práticas.

Observamos que, suportados pela teoria do *e-WoM*, os usuários a fim de reforçar a confiança de si e de novos consumidores, bem como punir os vendedores que não desempenham como o esperado e ser reconhecidos por seus pares apresentam comportamentos que reforçam o engajamento em situações negativas dentro das plataformas.

Bem como que a correta identificação de sua frustração propicia dados importantes às empresas para a manutenção e retenção destes consumidores, bem como o fortalecimento de sua marca junto a eles.

Observamos isto pelos resultados observados entre todas as plataformas avaliadas no que diz respeito a relação de avaliações e caracteres utilizados no UGC, evidenciando que os usuários buscam a interação em sustentar suas avaliações e disponibilizar o máximo de informação possível a outros usuários.

Ainda pela plataforma principal da análise, a Amazon, observamos um alto engajamento na avaliação do quanto os comentários anteriores ajudaram novos compradores:

Amazon amostra completa (Tabela 61):

Tabela 61: Tabela de correlação de Pearson – Amostra completa - Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,02970317	0,10672970	0,17694140	0,22176230
Review Score	-	-	-0,06077895	0,06455016	-0,05344780
Score (Sent)	-	-	-	0,03719594	0,03987905
Price	-	-	-	-	0,06372439
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-2,97%	10,67%	17,69%	22,18%
Review Score	-	-	-6,08%	6,46%	-5,34%
Score (Sent)	-	-	-	3,72%	3,99%
Price	-	-	-	-	6,37%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Amazon amostra positiva por análise de sentimentos (Tabela 62):

Tabela 62: Tabela de correlação de Pearson – Amostra positiva - Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-0,12313980	0,15099820	0,11433650	0,21033380
Review Score	-	-	0,08762308	0,03183888	-0,04976920
Score (Sent)	-	-	-	0,02783936	0,03739310
Price	-	-	-	-	0,05993821
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	-12,31%	15,10%	11,43%	21,03%
Review Score	-	-	8,76%	3,18%	-4,98%
Score (Sent)	-	-	-	2,78%	3,74%
Price	-	-	-	-	5,99%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Amazon amostra neutra por análise de sentimentos (Tabela 63):

Tabela 63: Tabela de correlação de Pearson – Amostra neutra - Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,05518685	0,08819398	0,18028610	0,15959600
Review Score	-	-	-0,03217707	0,09561335	-0,11593910
Score (Sent)	-	-	-	0,03478577	-0,02491474
Price	-	-	-	-	0,07614760
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	5,52%	8,82%	18,03%	15,96%
Review Score	-	-	-3,22%	9,56%	-11,59%
Score (Sent)	-	-	-	3,48%	-2,49%
Price	-	-	-	-	7,61%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Amazon amostra negativa por análise de sentimentos (Tabela 64):

Tabela 64: Tabela de correlação de Pearson – Amostra negativa - Amazon

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	0,05518685	0,08819398	0,18028610	0,21919290
Review Score	-	-	-0,03217707	0,09561335	-0,02392301
Score (Sent)	-	-	-	0,03478577	0,03628374
Price	-	-	-	-	0,05826910
Review Help	-	-	-	-	-

	Nº de Char	Review Score	Score (Sent)	Price	Review Help
Nº de Char	-	5,52%	8,82%	18,03%	21,92%
Review Score	-	-	-3,22%	9,56%	-2,39%
Score (Sent)	-	-	-	3,48%	3,63%
Price	-	-	-	-	5,83%
Review Help	-	-	-	-	-

Fonte: Elaboração própria.

Observamos aqui que é uso de números de caracteres (Nº de Caracteres) x auxílio do review (Review Help) nas correlações Pearson foi de 22,18% na amostra completa e diferenciou-se de acordo com o sentimento, e desta forma a variação de engajamento do usuário em 15,96% na amostra neutra, 21,92% na amostra negativa e 21,03% na positiva.

Já quando comparamos a influência da avaliação de ajuda recebida pelos usuários contra a avaliação objetiva do produto/serviço (Review Score x Review Help) observamos para a amostra completa -5,34%, para a amostra neutra -11,59%, para a amostra positiva -4,98% e para a amostra negativa -2,39%. Isto ilustra o comportamento dos usuários que de fato dão

mais importância para as amostras neutras e negativas, intensificando a interação e o sentimento de alerta entre eles.

Isto mostra que para comentários neutros (que expressam o conteúdo mistos em suas avaliações) e negativos a quantidade de caracteres influencia menos que nos positivos, porém indica uma participação e comentários ativos da comunidade entre si, dado a intensificação da leitura e avaliação das críticas para as avaliações neutras e positivas levando em conta que correlações em interações humanas comumente apresentam dados abaixo de 50%.

Como demonstrado na teoria do consumidor (Bynolfsson & Smith, 2000), (Clay et. Al., 2001), Chevalier e Goolsbee (2003^a, 2003b) este engajamento de comunidade, de forma indireta cria uma comunidade fidelizada a entidade que gere tal comércio e que mantém a sua frequência, conforme evidenciado acima, desta forma assumimos que nossa H1 se comprova como verdadeira.


- ✓ H2 – A percepção subjetiva do consumidor (UGC) não acompanha a direção do rating concedido no score do *Crowdvoting*.

Na análise das empresas americanas observamos, após executar a análise de sentimento dos comentários dados que estes não acompanham as avaliações dos *scores* objetivos (*Review Score*). Este descolamento se mostra importante por ir contra concepções adotadas em estudos diversos sobre o tema na academia, por exemplo nos estudos de Resnick (2000) que discorre sobre o maior volume de avaliações positivas em sistemas reputacionais.

Ao analisar sobre a visão subjetiva vemos que isto não ocorre na amostra da plataforma da empresa Amazon e que se apresenta de forma mais discreta nas demais, com exceção da base de dados da Olist.


Amazon

Gráfico de quantidade por reviews objetivos (Figura 16):

Figura 16: Gráfico de Barras de quantidade de Reviews por Score

Fonte: Elaboração própria.

Gráfico de quantidade por reviews de sentimentos (Figura 17):


Figura 17: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.

Fonte: Elaboração própria.

Bestbuy

Gráfico de quantidade de reviews objetivos (Figura 18):


Figura 18: Gráfico de Barras de quantidade de Reviews por Score.



Fonte: Elaboração própria.

Gráfico de quantidade de reviews por análise de sentimentos (Figura 19):

Figura 19: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.




Fonte: Elaboração própria.

ToyRus

Gráfico de quantidade de reviews objetivos (Figura 20):


Figura 20: Gráfico de Barras de quantidade de Reviews por Score.



Fonte: Elaboração própria.

Gráfico de quantidade de reviews por sentimentos (Figura 21):


Figura 21: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.



Fonte: Elaboração própria.

Olist


Distribuição de quantidades de Reviews objetivos (Figura 22):



Fonte: Elaboração própria.

Distribuição de quantidades de Reviews subjetivos (Figura 23):

Figura 23: Gráfico de Barras de quantidade de Reviews pela visão da análise de sentimentos.



Fonte: Elaboração própria.

Este comportamento também foi reforçado pelas regressões lineares realizadas, a fim de analisar o relacionamento entre a análise de sentimentos e os scores objetivos, mostrando que

a variável dependente Review Score (*score* objetivo das avaliações, se relaciona de forma importante com a análise de sentimento efetuada.

Estudos comprovam que a avaliação dos usuários exerce influência direta no estabelecimento da confiança do consumidor e no processo decisório de compra de produtos (Chevalier & Mayzlin, 2006), e a percepção incorreta sobre estas avaliações leva a crer que estas exercem influência sobre a performance dos produtos em seu processo como todo, e merece ser revisitada por novos estudos e pelas empresas que baseiam suas ações de marketing e resposta a falhas de processos aos indicativos dados pelo *score* objetivo dos usuários.

- ✓ H3 – Em ambientes globalizados os efeitos do *crowdvoting* se mantêm independentemente da localização geográfica de seus consumidores (comparativo USA x BR).

Ao efetuar o cruzamento das empresas americanas conseguimos observar que no geral se comportam de forma semelhantes frente ao despenho do *crowdvoting*. Observamos apenas uma diferença entre elas, a empresa Amazon, ao ser submetida a análise de sentimentos, apresentou mais comentários negativos do que positivos, indo em contramão aos estudos atuais e as outras duas empresas analisadas. Porém ao observamos pelo *score* objetivo o comportamento é semelhante.

Desta forma entendemos que poderíamos aceitar o comparativo destas duas contra a empresa brasileira e mesmo a Amazon contra esta, apesar das janelas de tempo observadas serem diferentes entre elas.

As empresas Bestbuy e ToyRus apresentam a intersecção de tempo necessária entre a Amazon e a Olist. Desta forma após compararmos as três empresas americanas e observamos dados semelhantes, efetuamos o comparativo junto a empresa brasileira Olist.

As evidências apresentadas mostram que estas atuam de forma semelhante dentro da estratégia do *crowdvoting*.

Quadro resumido (Tabela 65), apenas da correlação da Pearson para recuperação dos argumentos anteriores.

Tabela 65: Tabela comparativa de correlação de Pearson – empresas americanas

Correlação Pearson		Amazon	Bestbuy	ToyRus
Nº de Char	Review Score	-2,97%	-9,56%	-15,10%
Review Score	Score (Sent)	-6,08%	-4,53%	-3,08%
Score (Sent)	Nº de Char	10,67%	12,69%	11,37%

Fonte: Elaboração própria.

Observamos que as empresas apresentam correlações no mesmo sentido e de intensidade próximas, reforçando a percepção de funcionamento semelhante e possibilitando a triangularização para comparação com a empresa brasileira, através da base de dados da *Amazon*.

Feita a triangularização, colocamos o comparativo da correlação de Pearson para suportar a análise, mais aprofundada no capítulo de análise de dados, conforme a Tabela 66:

Tabela 66: Tabela comparativa de correlação de Pearson – Amazon x Olist

		Amazon	Olist
Nº de Char	Review Score	-2,97%	-37,97%
Nº de Char	Price	17,69%	5,10%
ReviewScore	Price	6,46%	-1,48%

Fonte: Elaboração própria.

Observamos que a empresa brasileira se porta de forma semelhante as americanas, porém com intensidades importantes observadas. Observamos um maior peso na quantidade de caracteres contra o *score* de avaliação, o que deve ser mais estudado, pois sua causa pode ser desde a formação acadêmica do brasileiro frente ao consumidor americano quanto a características culturais que nos levam a nos expressar com mais ou menos palavras.

Outro ponto interessante a ser aprofundado é a diferença do impacto do preço frente a avaliação, ainda que as correlações apresentem valores baixos, a diferença no sentido da correlação pode indicar uma resposta diferenciada para os brasileiros frente ao preço do produto, seja por atribuir um valor de *status* maior a este ou por se preocupar frente a aceitação social de reclamar de produtos de alto valor agregado.

Também observamos que a empresa brasileira sofre da mesma distorção das avaliações quando feitas pelo *score* objetivo, e que isto deve ser tratado aqui também.

Desta forma concluímos que, ainda que com intensidades diferentes, a estratégia de *crowdvoting* se aplica de forma similar em empresas brasileiras, como nas americanas, desta forma confirmando a hipótese H3.

5 CONCLUSÕES

A partir deste estudo pudemos observar o comportamento de diferentes empresas que utilizam sistemas reputacionais para sustentar um ambiente de *crowdvoting* sobre os serviços/produtos ofertados aos seus clientes. Pode-se observar os efeitos da utilização de estratégias de *crowdvoting* nestas estruturas como forma de oferecer a confiança necessária para que estes usuários a utilizem na aquisição de bens e serviços, por criar e gerir a rede social de cada varejo (Resnick, 2006; Dellarocas 2003).

Em consonância com estudos de impactos de estratégias de *crowdvoting* na *performance* de vendas de produtos (Alves, 2019), observamos que o uso de estratégias de *crowdvoting* exercem influência direta nos consumidores de produtos destes varejos eletrônicos. Desta forma, entendemos que uma métrica que reflita de melhor forma a percepção deste consumidor é benéfica e apresenta um diferencial importante para empresas que atuam neste segmento. Assim entendemos que a avaliação da percepção dos usuários, dada de forma subjetiva em suas críticas é relevante no sucesso da estratégia de *crowdvoting* em varejos eletrônicos.

Para esta conclusão, este trabalho fez uso de 94.595 *reviews*, analisados tanto por sua avaliação objetiva (scores com nota de 1 a 5) e subjetiva (UGC destes usuários sobre os produtos/serviços consumidos). Utilizamos 53.392 *reviews* para análise do comportamento destes no cenário americano e 41.203 avaliações para o cenário brasileiro a fim de obtermos amostras representativas para uma visão mais profunda destes comportamentos.

Observamos dentro da proposta deste trabalho, que empresas de varejo eletrônico situadas nos Estados Unidos, operam suas plataformas reputacionais e suas estratégias de *crowdvoting* de forma semelhante, permitindo a comparação entre os efeitos desta estratégia entre si e na colaboração na percepção de seus efeitos em múltiplos cenários ao compor os quadros comparativos desta.

E a partir destas amostras, observamos que as avaliações objetivas feitas pelos usuários (avaliações de 1 a 5 estrelas sobre sua satisfação com o serviço) não refletem a sua real percepção sobre o serviço/produto consumido. Ao efetuarmos a análise de sentimento, a partir de técnicas de *machine learning* e inteligência artificial, vemos que o que tem sido expressado nos comentários que suportam estas notas (UGC gerado dentro das plataformas em forma de texto), por muitas vezes vai não acompanhar a nota dada e expressa insatisfação contra a satisfação esperada pela nota do score objetivo.

Os resultados obtidos nos levam a defender que o acompanhamento do conteúdo subjetivo gerado pelos usuários, a partir da interpretação de suas críticas textuais, é um caminho melhor na mensuração da satisfação deste do que o acompanhamento por meio do score objetivo, já que este índice falha em expressar o sentimento do usuário.

Os dados deste estudo também indicam que as empresas norte americanas apresentaram uma disparidade maior, entre o *score* objetivo e a análise de sentimentos feita, do que a brasileira. Ainda que está também presente este efeito é notadamente menor. Ainda assim, observamos este acontecimento frente as quatro bases analisadas.

Este ponto nos leva a uma visão divergente da literatura atual, a qual espera que sistemas reputacionais recebem mais avaliações positivas do que negativas (Resnick, Zeckhauser, Friedman & Kuwabara, 2000), além de ser um ponto estratégico na tratativa de problemas junto aos consumidores, seja para a identificação do momento certo para atuar com promoções e descontos, ou para correção de falhas que resultam na perda de clientes e no comprometimento da marca.

Outro ponto relevante foi a análise e comparação de uma empresa de varejo eletrônico brasileira e sua comparação com empresas norte americanas, outros estudos fizeram comparações entre varejos eletrônicos no Japão (Lin, Manohar, & Kalwani, 2018), Canada e China, mas até o presente momento, não é de nosso conhecimento algum outro estudo que tenha feito comparativo com uma empresa brasileira. onde pudemos identificar que no geral a plataforma se estabelece de forma semelhante entre os dois países, porém para o público brasileiro algumas particularidades que diferem da percepção das demais empresas americanas.

Como pontos de diferenças entre o mercado americano e o brasileiro, observamos que em caso de insatisfação do consumidor, para o mercado brasileiro, o número de caracteres utilizado é expressivamente menor do que nas empresas norte americanas. Os dados também mostram que frente ao preço do produto, ainda que atuem de forma parecida, o consumidor brasileiro, demonstrou uma relação consideravelmente menor entre a relação do preço e o número de caracteres utilizado em suas avaliações.

Desta forma sugere-se que novos estudos se aprofundem no efeito que a geolocalização e a formação cultural distintas destes consumidores exercem nas percepções de produtos ofertados dentro destas plataformas. Também se sugere uma aproximação com a identificação dos grupos que compõem estas redes de avaliações de pares a fim de analisar seus efeitos na mensuração da percepção destes, a fim de explorar se os pontos de divergência observados no segmento de eletrônicos se repetem em outros grupos de produtos.

Estudos anteriores obtiveram percepções distintas ao avaliar o segmento de livros e filmes (Chevalier & Mayzlin, 2003) frente aos resultados deste trabalho que focou no segmento de eletroeletrônicos. Estas diferenças podem ser originadas por usuários de públicos distintos, indicando a formação de subgrupos dentro da rede de consumidores de cada varejo, e que se assim for, podem ter benefícios de estrutura a pesquisa ao segregar grupo de interesse de acordo com suas características socioeconômicas.

É interessante, junto da identificação do público destas redes, aprofundar em novos estudos a análise de sentimento aplicada aos UGC a fim de trabalhar com os efeitos de ironias para obter uma variável ainda mais efetiva na análise dos sentimentos destes consumidores.

Assim, pelos resultados obtidos, temos a percepção de que estratégias de *crowdvoting* fornecem um ambiente propício à fidelização de clientes e na performance dos produtos ali ofertados, uma vez que a comunidade de redes ao se manifestar e buscar a aprovação de seus pares e compartilhar suas percepções sobre os produtos acaba por gerar engajamento colabora na manutenção do diálogo entre empresa e seu público (Chevalier & Goolsbee, 2003^a, 2003b).

Desta forma, é importante que o diálogo seja claro entre as partes para que se tire o maior proveito possível do capital econômico latente destas interações entre a empresa, os consumidores e seus pares, e para isto a análise do UGC gerado ao invés do uso dos scores objetivos é relevante e o estudo entende que deve ser aplicada para a obtenção de melhores resultados na aplicação deste tipo de estratégia.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- Alves, M. Crowdvoting: Impacts on Product Sales in Marketplaces. (2019). *International Journal of Business Administration*. V.10, n3.
- Amabile, T., S. Barsade, Mueller, J. & Staw, B. *Affect and Creativity at Work*. Admin. Sci. Quart., v. 50, pp. 367-403, 2005.
- Aaker, David Allen; Joachimsthaler, Erich. (2007). *Como construir marcas líderes*. Porto Alegre: Bookman,
- Agag, G. M., & El-Masry, A., A. (2017). Why do consumers trust online travel websites? Drivers and outcomes of consumer trust toward online travel websites. *Journal of Travel Research*, 56(3), 347-369.
- Akehurst, G. (2009). *User generated content: the use of blogs for tourism organizations and tourism consumers*. Service Business, 3(1), 51-61.
- Axelrod, R. (2011). *The Evolution of Cooperation*. 1984. New York: Basic Books.
- Baird, C.H. & Parasnis, G. *From social media to social customer relationship management*. Strategy & Leadership, 39(5): 30–37, Recuperado de <https://doi.org/10.1108/10878571111161507>
- Barreto, A.M. (2013). Do users look at banner ads on Facebook?, *Journal of Research in Interactive Marketing*, 7(2): 119–139, Recuperado de <https://doi.org/10.1108/JRIM-Mar-2012-0013>.
- Blackwell, R. D; Miniard, P. W.; Engel, J. F. (2013). *Comportamento do Consumidor*. São Paulo: Cengage Learning,
- _____. *Comportamento do Consumidor*. São Paulo: Pioneira Thomson Learning, 2005.
- Bons, E., Daams, M., Neijns, E., Ottenheim, D., Segeren, M. & Van Der Sommen, G. (2010). *Open innovation: The benefits of crowdsourcing*. Working paper, Tilburg University, Netherlands.
- Brabham, D. C. (2010). *Crowdsourcing as a model for problem solving: leveraging the collective intelligence of online communities for public good*. Tese (Doutorado em Filosofia) – Universidade de UTAH. Recuperado de <http://content.lib.utah.edu/utils/getfile/collection/etd2/id/1190/filename/419.pdf> Acesso 15 set 2014.
- _____. (2008). Moving the crowd at iStockphoto: The composition of the crowd and motivations for participation in a crowdsourcing application. First Monday, v. 13, n 6, jun. Recuperado de <http://firstmonday.org/article/view/2159/1969>. Acesso 28 ago. 2014.

- Brynjolfsson, E. & Smith, M. (2000) “*Frictionless Commerce? A Comparison of Internet and Conventional Retailers*”, *Management Science* 46, 563-585.
- Castanheira, M.; Peixoto, J.; & Fachada, T. *Conhecimento, reflexividade e desempenho: Anotações para uma discussão*. Rio de Janeiro. Papel Virtual Editora. 2003.
- Cheung C.M.K. & Thadani D.R. (2012). The impact of electronic word-of-mouth communication: a literature analysis and integrative model. *Decision Support Systems* 54(1): 461–470. Recuperado de <https://doi.org/10.1016/j.dss.2012.06.008>
- Chevalier, J. & Mayzlin, D. (2003) “The Effect of Word of Mouth On Sales: Online *Book Reviews*”, NBER working paper, nº 10148.
- Chevalier, J. & Mayzlin, D. (2006) The effect of word of mouth online: Online book reviews. *Journal of Marketing Research* 43(3): 345–354.
- Christodoulides, G., Jevons, C., & Bonhomme, J. (2012) Memo to Marketers: Quantitative Evidence for Change How User-Generated Content Really Affects Brands. *Journal of Advertising Research*, 52(1), 53-64.
- Chu S.C. & Choi S.M. (2011). Electronic word-of-mouth in social networking sites: a cross-cultural study of the United States and China. *Journal of Global Marketing*, 24(3): 263–281. Recuperado de <https://doi.org/10.1080/08911762.2011.592461>.
- Chu S.-Ch. & Kim Y. (2011). Determinants of consumer engagement in electronic word-of-mouth (eWOM) in social networking sites. *International Journal of Advertising* 30(1): 47–75, Recuperado de <https://doi.org/10.2501/IJA-30-1-047-075>.
- Clay, K., Krishnan, R. & Wolff, E. (2001) “Prices and Price Dispersion on the Web: Evidence from the Online Book Industry”, *The Journal of Industrial Economics* 49, 521-540.
- Dellarocas C (2003) *The digitization of word of mouth: promise and challenges of online feedback mechanisms*. *Manag Sci* 49(10):1407–1424
- Doan, A., Ramakrishnan, R. & Halevy, A.Y. (2010). Crowdsourcing systems on the World-Wide Web, *Communications of the ACM*, 54, 86, 2011. doi: 10.1109/TKDE.188
- Edelman D.C. (2010). Branding in the digital age: you’re spending your money in all the wrong places. *Harvard Business Review* 88: 62–69.
- Engel, J. F.; Blackwell, R. D.; & Miniard, P.W. (2000). *Comportamento do consumidor*. Rio de Janeiro: LTC, 8ª edição 2000.
- Erkan I. & Evans Ch. (2016). The influence of eWOM in social media on consumers’ purchase intentions: An extended approach to information adoption. *Computers in Human Behavior*, 61: 47–55. recuperado de <https://doi.org/10.1016/j.chb.2016.03.003>.

- Filieri, R., Alguezaui, S., & McLeay, F. (2015) *Why do travelers trust TripAdvisor? Antecedents of trust towards consumer-generated media and its influence on recommendation adoption and word of mouth*. *Tourism Management*, 51, 174-185.
- Fiske, S.T. (1980). Attention and weight in person perception: The impact of negative and extreme behavior. *Journal of Personality and Social Psychology*, 38, 6–906
- Forman, C., Ghose, A., & Wiesenfeld, B. (2008) Examining the Relationship Between Reviews and Sales: The Role of Reviewer Identity Disclosure in *Electronic Markets*. *Information Systems Research*, Vol. 19(3):291-313
- Gade, C. *Psicologia do comportamento do consumidor*. Editora Pedagógica e universitária Ltda, 1980.
- Galindo, Daniel dos Santos.(2008).*Comunicação mercadológica: uma visão multidisciplinar: São Bernardo do Campo: Universidade Metodista de São Paulo*.
- Geiger, D., Rosemann, M. & Fielt, E. (2011). *Crowdsourcing information systems – A systems theory perspective*. Australasian Conference on Information Systems (ACIS), Sydney, Australia.
- Geng Cui, Hon-Kwong Lui & Xiaoning Guo (2012) The Effect of Online Consumer Reviews on New Product Sales, *International Journal of Electronic Commerce*, 17:1, 39-58, DOI: 10.2753/JEC1086-4415170102
-
- _____. & Annamma Joy (2008) Consumers' Attitudes toward Marketing: A Cross-cultural Study of China and Canada, *Journal of International Consumer Marketing*, 20:3-4, 81-93, DOI: 10.1080/08961530802129466
- George, C. & Scerri, J. (2007). Web 2.0 and User-Generated Content: legal challenges in the new frontier. *Journal of Information, Law & Technology*.(2). ISSN:1361-4169
- Ghose & P. G. Ipeirotis (2011). "Estimating the Helpfulness and Economic Impact of Product Reviews: Mining Text and Reviewer Characteristics," in *IEEE Transactions on Knowledge and Data Engineering*, vol. 23, no. 10, pp. 1498-1512.
- Gioia, M.R. (2006). Fundamentos de marketing: *Conceitos básicos*. São Paulo: Saraiva, 2006.
- Godes, D. & Mayzlin, D. (2003) “*Using Online Conversations to Study Word of mouth Communication*”, Yale SOM working paper.
-
- _____. (2004). Using online conversation to study word-of-mouth communication. *marketing Science*, 23, 545–561.
- Grégoire Y. Salle A. & Tripp T.M. (2014). Managing social media crises with your customers: the good the bad and the ugly. *Business Horizons*58(2): 173–182 <https://doi.org/10.1016/j.bushor.2014.11.001>

- Heyes, Anthony & Kapur, Sandeep (2012). "Angry customers, e-word-of-mouth and incentives for quality provision," *Journal of Economic Behavior & Organization*, Elsevier, vol. 84(3), pages 813-828.
- Howe, J. (2008). *O Poder das Multidões*. São Paulo: Elsevier Técnico.
- Hsin-Chen Lin & Manohar U. Kalwani (2018) Culturally Contingent Electronic Word-of-Mouth Signaling and Screening: A Comparative Study of Product Reviews in the United States and Japan. *Journal of International Marketing*: June 2018, Vol. 26, No. 2, pp. 80-102. <https://doi.org/10.1509/jim.17.0016>
- Huang, M., Cai, F., Tsang, A.S.L. & Zhou, N. (2011). Making your online voice loud: the critical role of WOM information. *European Journal of Marketing*, 45(7/8): 1277–1297, <https://doi.org/10.1108/0309561111137714>
- J. A. Chevalier & A. Goolsbee. (2003). "Measuring prices and price competition online: Amazon.com and BarnesandNoble.com," *Quantitative Marketing and Economics*, vol. 1, no. 2, pp. 203–222.
- Jansen, B.J., Zhang, M., Sobel, K. & Chowdury, A. (2009). Twitter power-tweets as electronic word-of-mouth, *Journal of the American Society for Information Science and Technology*, 60(11), p.2169-2188;
- Kapferes, J. N. (2004) *O que vai mudar as marcas*. Porto Alegre. Bookman.
- Kaplan, A. M., & Haenlein, M. (2010). *Users of the world, unite!* The Challenges and opportunities of Social Media, *Business Horizons*, 53, 59-68.
- Karsklian, E. *O Comportamento do Consumidor*. São Paulo: Editora Atlas, 2000.
- Keller, K. L. *Administração de marketing*. 12ª ed. Rio de Janeiro: Prentice Hall, 2006.
- _____. *Strategic brand management: building, measuring, and managing brand equity*. 4a ed. Pearson Education, 2013.
- Kotler, P., & Armstrong, G. (2007) *Princípios de marketing*. São Paulo: Pearson Prentice Hall.
- _____.; Keller, K. L.(2012). *Administração de Marketing*. 14ed. São Paulo: Pearson Education do Brasil.
- Kotler, Philip. (2000). *Administração de marketing: a edição do novo milênio*. 10ª ed. São Paulo: Prentice Hall..
- Kucukemiroglu S. & Kara A. (2015). Online word-of-mouth communication on social networking sites: An empirical study of Facebook users. *International Journal of Commerce and Management* 25(1):2–20 <https://doi.org/10.1108/IJCoMA-11-2012-0070>.
- Lévy, P. (1998). *A inteligência Coletiva, por uma antropologia do ciberespaço*. São Paulo: Edições Loyola.

-
- . O que é virtual? São Paulo, Ed. 34, 1996. 157p. 1996.
- Lin H. Fan W. & Chau P.Y. (2014). Determinants of users' continuance of SNS: a self-regulation perspective. *Information & Management* 51(5): 595–603. Recuperado de <https://doi.org.10.1016/j.im.2014.03.010>
- Lobato, R., Thomas, J., & Hunter, D. (2011). Histories of User-Generated Content: between formal and informal media economies. *International Journal of Communication*, 5, 899-914.
- M. Ma & R. Agarwal. (2007). "Through a glass darkly: Information technology design, identity verification, and knowledge contribution in *online communities*," *Information Systems Research*, vol. 18, no. 1, pp. 42–67, Mar. 2007.
- Marketing Future Cast Lab, I. U. L. G. (2012). *Marketing Trends* (H. Piriquito, Ed.) Vol. 1. Deplano Network.
- Mowen, J. C.; Minor, M. S. *Comportamento do Consumidor*. São Paulo: Prentice Hall, 2003.
- Nicosia, F. M. (1966) *Consumer decision processes*: Marketing and advertising implications. Englewood Cliffs, New Jersey: Prentice-Hall.
- Nonaka, I. & Takeuchi, H. (1997). *Criação de conhecimento na empresa*. Rio de Janeiro: Campus.
- Noort, G. V.; Willemsen, L. M. (2011); Online Damage Control: The Effects of Proactive Versus Reactive Webcare Interventions in Consumer-Generated and Brand-generated Platforms. *Journal of Interactive Marketing* Vol. 26, 131-140.
- Noubel, J. F. (2004). *Collective Intelligence: The Invisible Revolution*. Recuperado de <http://publishing.yudu.com/Library/Arswi/CollectiveIntelligen/resources/index.htm>. Acesso em 25 out. 2014.
- Phelps, J. E.; Lewis, R.; Mobilio, L.; Perry, D.; & Raman, N. (2004). Viral marketing or electronic word-of-mouth advertising: Examining consumer responses and motivations to pass along email. *Journal of Advertising Research*, 23, 4. 370-378.
- Prahalad, C. K.; Ramaswamy, V. (2014). Co-creation experiences: The next practice in value creation. *Journal of interactive marketing*, v. 18, n. 3, jun. 2004. Recuperado de <https://www.cs.cmu.edu/~jhm/Readings/Co-creating%20unique%20value%20with%20customers.pdf>>. Acesso em 19 set.
- Purgat, B. M. (2018) International Contexts of Social media and e-WoM Communication in the Customer Decision-Making Process. *Journal of Management and Business Administration*. Central Europe. Vol. 26(2) 16-33. ISSN 2450-7814
- Resnick, P., R. Zeckhauser, E. Friedman, & K. Kuwabara. (2000). *Reputation systems*. Comm. ACM 43(12) 45–48.

- Resnick, P., Zeckhauer, R., Swanson, J. & Lockwood, K. (2006) The value of reputation on eBay: A controlled experiment. *Experimental Economics* 9: (2): 79-101.
- Santos, A. T.; Demarco, M. A. C.; & Tavares, D. C. (2016). *Marketing 3.0 e Novas Formas de Interação com o Público na Era Digital*. Intercom – Sociedade Brasileira de Estudos Interdisciplinares da Comunicação XXXIX Congresso Brasileiro de Ciências da Comunicação. São Paulo.
- Schenk, E.; Guittard, C. (2009). *Crowdsourcing: What can be outsourced to the crowd, and why?* Working paper of Graduate School of Science and Technology, Recuperado de <https://halshs.archives-ouvertes.fr/halshs-00439256v1>. Acesso 02 set. 2014.
- Schiffman, L. G.; Kanul, L. L. (2000). *Comportamento do consumidor*. 6ª. Ed. Rio de Janeiro: LTC – Livros Técnicos e Científicos.
- Schultz, Don E.; Barnes, Beth E. (2006). *Campanhas estratégicas de comunicação de marca*. Rio de Janeiro: Qualitymark Ed.
- See-To E.W.K. & Ho K.K.W. (2014). Value co-creation and purchase intention in social network sites: the role of electronic word-of-mouth and trust – a theoretical analysis. *Computers in Human Behaviour* 31(1): 182–189. Recuperado de <https://doi.org/10.1016/j.chb.2013.10.013>.
- Semprini, Andrea. (2006). *A marca pós-moderna: poder e fragilidade da marca na sociedade contemporânea*. São Paulo: Estadão das Letras Editora.
- Serralvo, F. A. (2004). *Factores de Influencia em el Comprtamiento del turista intertno. Turismo, ocio y deporte: VIII Congreso de Sociologia*. 187-202. ISBN: 84-9749-121-1 2004.
- Shimp, Terence. (2002). *Propaganda e promoção: aspectos complementares da comunicação integrada de marketing*. Porto Alegre: Bookman, 2002.
- Shirky, C. (2008) *Here comes everybody: the power of organizing without organizations*. London: Penguin Books Ltd. Recuperado de https://uniteyouthdublin.files.wordpress.com/2015/01/here_comes_everybody_power_of_organizing_without_organizations.pdf. Acesso em 10 de dezembro de 2019.
- Shostack, G. L. (1985). *Planning the Service Encouters, in Czepiel, J.A., Somon, M. R., & Surprenant, C.F. The Service Encounters*. New York> Lexington Books.
- Sigala, Marianna. (2012). Social Media and Crisis Management in *Tourism: Applications and Implications for Research*. *Information Technology & Tourism*, Vol. 13, pp 1-000. DOI:1098-3058/12.
- Skowronski, J.J., & Carlston, D.E. Negativity and extremity biases in impression formation: A review of explanations. *Psychological Bulletin*, 105, 1 (1989), 131–142.
- Slawsby, A. ; Rivera, C. (2007). *Collective Innovation*. Massachusetts Institute of Technology. Disponível em < <http://dspace.mit.edu/handle/1721.1/39518>>. Acesso 02 set. 2014.

- Solomon, M.R. (2011). *O Comportamento do consumidor: comprando, possuindo e sendo*. Porto Alegre: Bookman..
- Vitelli, A.P. (2003). *As universidades corporativas e sua contribuição para a gestão do conhecimento nas organizações*. Dissertação de Mestrado. São Paulo: FGV-EAESP. 200p.
- Wallace E. Buil E. & De Chernatony L. (2014). Consumer engagement with self-expressive brands: brand love and WOM outcomes. *Journal of Product & Brand Management* 23(1): 33–42 Recuperado de <https://doi.org/10.1108/JPBM-06-2013-0326>
- Wang T. Yeh R.K-J. Chen Ch. & Tsydypov Z. (2016). *What drives electronic word-of-mouth on social networking sites?* Perspectives of social capital and self-determination. *Telematics and Informatics* 33(4): 1034–1047 Recuperado de <https://doi.org/10.1016/j.tele.2016.03.005>
- White, Roderick. (2004). Marcas e publicidade. IN: Jones Philip (Org.) *A publicidade na construção de grandes marcas*. São Paulo: Nobel. p. 77-93.
- Wolley, A. W. et al. Evidence for a Collective Intelligence Factor in the Performance of Human Groups. *Science*. v. 330, n. 6004, pp. 686-688, out 2010. Recuperado de <http://www.sciencemag.org/content/330/6004/686.short>. Acesso 02 ago. 2014.
- Wyatt, J. (2001). Management of Explicit and Tacit Knowledge. *Journal of the Royal Society of Medicine*. v. 94, n. 6-9.
- Zhang, Y.; Vásquez, C. (2014) *Hotels' responses to online reviews: Managing consumer dissatisfaction*. *Discourse, Context & Media*, vol 6, 54-64.

7 ANEXOS

ANEXO 1: ESTRUTURA DE DADOS DE CADA BANCO DE DADOS DISPONIBILIZADO

Base de dados da Amazon:

- *product/product Id: asin, e.g. amazon.com/dp/B00006HAXW*
- *product/title: title of the product*
- *product/price: price of the product*
- *review/userId: id of the user, e.g. A1RSDE90N6RSZF*
- *review/profileName: name of the user*
- *review/helpfulness: fraction of users who found the review helpful*
- *review/score: rating of the product*
- *review/time: time of the review (unix time)*
- *review/summary: review summary*
- *review/text: text of the review*

Base de dados ToyRus:

- *asins*
- *brand*
- *categories*
- *primaryCategories*
- *imageURLs*
- *keys*
- *manufacturer*
- *manufacturerNumber*
- *reviews.date*
- *reviews.dateSeen*
- *reviews.didPurchase*
- *reviews.doRecommend*
- *reviews.id*

- *reviews.numHelpful*
- *reviews.rating*
- *reviews.sourceURLs*
- *reviews.title*
- *tweet_text*
- *Sentiment*
- *Score*
- *reviews.username*
- *sourceURLs*
- *CharCount*

Base de dados Bestbuy:

- *id*
- *dateAdded*
- *dateUpdated*
- *name*
- *asins*
- *brand*
- *categories*
- *primaryCategories*
- *imageURLs*
- *keys*
- *manufacturer*
- *manufacturerNumber*
- *reviews.date*
- *reviews.dateSeen*
- *reviews.didPurchase*
- *reviews.doRecommend*
- *reviews.id*
- *reviews.numHelpful*
- *reviews.rating*
- *reviews.sourceURLs*
- *reviews.title*

- *tweet_text*
- *Sentiment*
- *Score*
- *reviews.username*
- *sourceURLs*

Base de dados Olist (ecommerce brasileiro):

- *review_id*
- *order_id*
- *review_score*
- *review_comment_title*
- *review_comment_message*
- *review_creation_date*
- *review_answer_timestamp*
- *ContChar*
- *Price2*
- *Ano*
- *Mês*

ANEXO 2: APRESENTAÇÃO DE DADOS SOBRE AS EMPRESAS SELECIONADAS PARA ESTUDO DE BASE DE DADOS

AMAZON:

A Amazon é uma empresa de comércio eletrônico que objetiva ser a empresa com o maior foco em consumidores do mundo, onde as pessoas possam encontrar e descobrir virtualmente qualquer coisa que eles possam querer comprar online. Por entregar aos consumidores mais do que eles esperam – preços baixos, ampla seleção de produtos e conveniência – a Amazon.com continua a crescer e se transformou numa plataforma de comercio eletrônico mundial.

Fundada por Jeff Bezos, o sítio eletrônico Amazon.com iniciou suas operações em 1995 como um lugar para comprar livros através da experiência única que a internet poderia oferecer aos amantes por livros. Bezos acreditou que apenas a internet poderia oferecer aos consumidores a conveniência de navegar através de seleções de milhares de livros através de uma única pesquisa. Após os primeiros 30 dias de operação, a Amazon.com preencheu pedidos de compra em cinquenta estados e quarenta e cinco países, todas enviadas de sua garagem em Seattle.

É através do desenho que a inovação tecnológica dirige o crescimento da Amazon.com para oferecer aos consumidores mais tipos de produtos, com mais conveniência, e com os menores preços. Através de muitas inovações tecnológicas para os consumidores a Amazon.com oferece uma experiência personalizada ao realizar suas compras para cada consumidor através de “*Search inside The Book*”, finalização da compra através de apenas 1 click e vários tipos de serviços voltados a comunidades, como a lista de desejos (www.amazon.com/wishlist), que auxiliam os consumidores a descobrirem novos produtos e efetuarem decisões de compras com mais informações.

Amazon.com opera através de sítios de venda onde oferece plataformas que permitem a terceiros a venderem seus produtos em seu sitio eletrônico. Os sites de vendas incluem: www.amazon.com, www.amazon.co.uk, www.amazon.de, www.amazon.co.jp, www.amazon.fr, www.amazon.ca, www.amazon.cn, www.amazon.it, www.amazon.es, www.amazon.com.br e www.amazon.in. Também provém plataformas para terceiros revendedores, para serviços promocionais e de marketing, e serviços baseados na internet para

desenvolvedores. Em adição, operam seus outros sítios eletrônicos, que incluem www.a9.com e www.alexa.com que permitem buscas e navegação e o www.imdb.com, uma base de dados compreensiva sobre filmes.

No ano 2000, a Amazon.com começou a oferecer o seu melhor em plataforma de comércio eletrônico para outros revendedores e para vendedores individuais. Hoje, mais de dois milhões de pequenos negócios, uma marca de venda mundial e de vendedores individuais aumentam seu volume de vendas e atingem novos consumidores por utilizarem o poder que o Amazon.com e sua plataforma de comércio eletrônico oferecem. Através de programas como vendendo no Amazon, Preenchimento pelo Amazon, Amazon loja de internet, Checkout pelo Amazon, propagandas de produtos e vantagens, vendedores de todos os tamanhos e formas oferecem sua seleção para os consumidores do Amazon.com usando vários de seus componentes oferecidos pela plataforma de comércio eletrônico.

Lançado em 2006, Amazon Web Services (AWS) começou a expor a chave para serviços de infraestrutura para serviços através da plataforma da internet, agora conhecido amplamente como computação em nuvem. O maior benefício obtido através da computação em nuvem e a AWS, é a habilidade de alavancar o novo modelo de negócio e tornar o custo do capital de infraestrutura em custo variável. Empresas não precisam mais planejar e projetar servidores e outros recursos de TI com semanas ou meses de intervalo, agora, através do AWS, o negócio pode tirar vantagem da experiência do Amazon e ter ganhos de economia de escala ao acessar os recursos apenas quando seus empreendimentos necessitam, entregando resultados com menor custo e mais rápidos.

Hoje a Amazon Web Services prove alta confiabilidade, baixo custo, ganhos de escala através de plataformas que operam nas nuvens que fornecem serviço a centenas de milhares de empresas, governos e startups em 190 países ao redor do mundo.

A evolução do sítio eletrônico da Amazon para a construção de uma plataforma de comércio eletrônico que incentivasse parcerias é dirigida pelo espírito da inovação, que é parte do DNA da companhia. As mentes mais brilhantes do mundo se dirigem à Amazon.com para pesquisa e desenvolvimento de tecnologia que possa melhorar as vidas de compradores, vendedores e desenvolvedores ao redor do mundo.

BESTBUY:

Best Buy Co. Inc. é uma multinacional Americana vendedora de eletrônicos com sua sede em Richfield, Minnesota. Foi originalmente fundada por Richard M. Schulze e James Wheeler em 1966 como uma loja especializada em áudio chamada Sound of Music. Em 1983, teve sua marca mudada para o nome atual com ênfase em produtos eletrônicos.

A Best Buy opera internacionalmente no Canada e no México e já operou na China até fevereiro de 2011 (quando se fundiu com a Five Star). A companhia também operou na Europa até 2012. Suas subsidiárias incluem a Geek Squad, Magnolia, Áudio Vídeo e Pacific Sales. A Best Buy também opera a Best Buy Mobile e a Insígnia *brands* na América do Norte, além da Five Star na China.

A Best Buy vende celulares da Verizon Wireless, AT&T Mobility, Sprint Corporation nos Estados Unidos. No Canada, as operadoras incluem a Bell Mobility, Rogers Wireless, Telus Mobility e compete com operadoras menores como a SaskTel.

Best Buy foi nomeada como a Companhia do Ano pela revista Forbes em 2004, Loja especializada da década pela Discount Store News em 2001, ranqueada na Top 10 da "America's Most Generous Corporations" pela Forbes em 2005, foi publicada na Fortune magazine's list of "Most Admired Companies" em 2006 e "The Most Sustainable Company in the United States" pela Barron's em 2019.

Hubert Joly foi o presidente executivo da Best Buy, e foi sucedido como CEO por Corie Barry em Junho de 2019.

TOYRUS:

Toys "R" Us é uma empresa vendedora de brinquedos, roupas e produtos de bebê cuja o proprietário é a empresa Tru Kids, Inc. (d.b.a. Tru Kids Brands). Ela foi fundada em abril de 1948, com sua sede localizada em Wayne, New Jersey, na área metropolitana de New York.

Fundada por Charles Lazarus em Junho de 1957, Toys "R" Us tem sua origem na loja de móveis de Lazarus, a qual ele iniciou em 1948. Ele adicionou brinquedos no seu catálogo e

eventualmente foi mudando o foco do negócio. A companhia tem permanecido no segmento de brinquedos por mais de 65 anos e operou mais de 800 lojas nos Estados Unidos e por volta de 800 lojas fora dos Estados Unidos, embora este número tenha diminuído de forma constante. No seu auge a Toys "R" Us foi considerada como um exemplo de matador de categoria, embora com o aumento dos comércios e das lojas online, a Toys "R" Us começou a perder seu espaço no mercado.

A companhia entrou em quebra em setembro de 2017 e seus operadores britânicos entram na administração em fevereiro de 2018. Em março de 2018, a companhia anunciou que ia fechar todas as lojas nos Estados Unidos e na Inglaterra. As localizações britânicas fecharam em abril e as americanas em junho. O braço australiano da entidade fechou suas lojas em agosto de 2018. As demais operações internacionais em mercados como a Ásia e a África foram menos afetadas, porém aos poucos foram vendidas para terceiros.

A companhia continua a operar como o licenciador das operações internacionais do grupo e que pretender relançar a marca nos estados Unidos no futuro. Em janeiro de 2019 a marca voltou da falência como Tru Kids.

OLIST:

Olist é um canal de vendas que se apresenta através dos principais *marketplaces* do Brasil e é formada por milhares de lojistas. Temo como missão fortalecer o comércio e tornar os produtos dos lojistas participantes em mais competitivos, aumentando assim a chance de venda destes.

A Olist conecta milhares de pequenos negócios por diversos canais de venda de varejos eletrônicos através de um único contrato, pelo qual estes comerciantes são capazes de vender seus produtos através da loja da Olist e enviar diretamente aos consumidores através dos parceiros logísticos da Olist.

Após a efetivação da compra, os vendedores são notificados para atender aquela ordem de compra e uma vez que o consumidor recebe o produto, ou quando a data de entrega não é respeitada, o consumidor recebe uma pesquisa de satisfação por e-mail onde ele pode avaliar a experiência de compra e seus comentários.


Desta companhia obtivemos um *dataset* com pedidos realizados entre 2016 a 2018 feitos por diversos *marketplaces* no Brasil. Esta base permite ver a ordem de venda sobre múltiplas dimensões, desde seu *status*, preço, pagamento, frete, atributos do produto e as *reviews* escritas pelos consumidores. Também é disponibilizada a geolocalização que se relaciona com o CEP brasileiro e as coordenadas de latitude e longitude.

São dados comerciais reais, que foram anonimizados e as referências sobre as empresas e seus parceiros nos textos foram substituídos por nomes das casas de *Game of Thrones*.

Estrutura do esquema de dados:

Os dados foram divididos em múltiplos bancos de dados para a melhor compreensão e organização.

Esquema de dados:



ANEXO 3: AUTORIZAÇÃO DO USO DO BANCO DE DADOS DA AMAZON

Milton Rodrigues

De: Julian McAuley <julian.mcauley@gmail.com>
Enviado em: quarta-feira, 8 de outubro de 2014 20:11
Para: Milton Rodrigues
Assunto: Re: Authorization of access to the Amazon product reviews information Dataset

Status do sinalizador: Sinalizada

Hi Milton,

Sure thing, a version of the dataset page with working links can be found here: <http://snap.stanford.edu/data/web-Amazon-links.html>

Remember to cite our RecSys paper if you use the data.

Julian

On 8 October 2014 14:44, Milton Rodrigues <miltonrra@gmail.com> wrote:

Dear Mrs. Mcauley:

I am a masters' degree student of Business Administration at PUC-SP (one of the top private universities in Brazil located in the State of São Paulo – Brazil) and my thesis focuses on crowdsourcing effects. As part of my work, I am conducting a quantitative analysis of the impact of the product reviews on their selling performance.

In that matter, with the only purpose of scientific research, I respectfully request your permission to utilize the dataset of amazon products reviews.

I remain at your full disposal for any clarification needed and thank you in advance for your attention.

Yours sincerely,

Milton Ruiz

ANEXO 4: REGRESSÕES POR AMOSTRA

4.1 Amostra - Amazon

Regressão linear múltipla das variáveis da Amazon – amostra integral:

Call:

```
lm(formula = `review/score` ~ Charcount + Sentiment_N + Review_Help)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-3.7386	-1.3348	0.4906	1.4915	1.7699

Coefficients:


	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	3.082e+00	1.560e-02	197.638	< 2e-16 ***
Charcount	1.567e-04	1.933e-05	8.109	5.29e-16 ***
Sentiment_N	2.828e-01	4.887e-03	57.868	< 2e-16 ***
Review_Help	-1.392e-01	1.757e-02	-7.922	2.41e-15 ***



Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Residual standard error: 1.459 on 35639 degrees of freedom

Multiple R-squared: 0.08881, Adjusted R-squared: 0.08873

F-statistic: 1158 on 3 and 35639 DF, p-value: < 2.2e-16







4.2 Amostra - Bestbuy

Regressão linear múltipla das variáveis da Bestbuy – amostra integral:

Call:

```
lm(formula = reviews.rating ~ CharCount + Sentiment_n + reviews.numHelpful)
```

Residuals:

	Min	1Q	Median	3Q	Max
Residuals	-3.7261	-0.3100	0.2770	0.3127	1.1567

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	4.217e+00	1.481e-02	284.673	< 2e-16 ***
CharCount	-1.669e-04	3.714e-05	-4.494	7.03e-06 ***
Sentiment_n	1.031e-01	3.289e-03	31.365	< 2e-16 ***
reviews.numHelpful	2.798e-03	1.355e-03	2.065	0.039 *



Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.7234 on 16064 degrees of freedom
(5 observations deleted due to missingness)

Multiple R-squared: 0.06696, Adjusted R-squared: 0.06678

F-statistic: 384.3 on 3 and 16064 DF, p-value: < 2.2e-16

```
> plot(regmultlin)
```



4.3 Amostra - ToyRus:

Regressão linear múltipla das variáveis da ToyRus – amostra integral

Call:

```
lm(formula = reviews.rating ~ CharCount + Sentiment...28 + reviews.numHelpful)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-3.7489	-0.4239	0.2573	0.3007	1.2236

Coefficients:


	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	4.0487290	0.0556724	72.724	<2e-16 ***
CharCount	-0.0003240	0.0001921	-1.686	0.0919 .
Sentiment...28	0.1427521	0.0110987	12.862	<2e-16 ***
reviews.numHelpful	-0.0170583	0.0135745	-1.257	0.2091



Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Residual standard error: 0.7524 on 1672 degrees of freedom

Multiple R-squared: 0.1115, Adjusted R-squared: 0.1099

F-statistic: 69.95 on 3 and 1672 DF, p-value: < 2.2e-16







4.4. 3 Regressão Linear – Olist (Br)

Regressão linear múltipla das variáveis da Olist – amostra integral

Call:

```
lm(formula = review_score ~ ContChar + Sentiment_N + Price2)
```

Residuals:

	Min	1Q	Median	3Q	Max
Residuals	-3.7663	-0.8185	0.4632	0.9523	3.5093

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	3.279e+00	3.564e-02	91.995	< 2e-16 ***
ContChar	-1.157e-02	2.310e-04	-50.065	< 2e-16 ***
Sentiment_N	2.891e-01	7.270e-03	39.759	< 2e-16 ***
Price2	1.499e-06	5.011e-07	2.991	0.00278 **

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1.394 on 17772 degrees of freedom
 Multiple R-squared: 0.2141, Adjusted R-squared: 0.214
 F-statistic: 1614 on 3 and 17772 DF, p-value: < 2.2e-16

