

UNIVERSIDADE ABERTA



INSTITUTO
SUPERIOR TÉCNICO



**Análise de sentimento e desempenho de participantes em *MOOC*
da Universidade Aberta de Portugal**

Herbert Laroca Mendes Pinto

Mestrado em Informação e Sistemas Empresariais
(mestrado em associação)

10/2019.

UNIVERSIDADE ABERTA

INSTITUTO
SUPERIOR TÉCNICO



**Análise de sentimento e desempenho de participantes em *MOOC*
da Universidade Aberta de Portugal**

Herbert Laroca Mendes Pinto

Mestrado em Informação e Sistemas Empresariais
(mestrado em associação)

Dissertação orientada pelo Professor Doutor
Vitor Jorge Ramos Rocio.

10/2019.

Resumo

A escrita é uma forma de registro da expressão humana. Durante a escrita são expressos fatos e opiniões, posteriormente armazenados em sistemas de informação. As plataformas de *e-learning* são ambientes educacionais de ensino à distância e exemplo de sistemas de informação que armazenam fatos e opiniões. Um caso específico de ambiente de e-learning é o *MOOC (Massive Open Online Course)*. O objetivo desta pesquisa é combinar quatro API (Interface de programação de aplicativo) de análise de sentimento, nomeadas *Amazon Comprehend*, *Google Natural Language*, *IBM Watson Natural Language Understanding* e *Microsoft Text Analytics* e criar a média ponderada dos *scores* destas APIs para efetuar a análise da polaridade do sentimento em um ambiente *MOOC*. Outro objetivo desta pesquisa é estudar se existe relação entre a polaridade de sentimento expressa nas intervenções online e o aproveitamento acadêmico dos participantes em *MOOC* da Universidade Aberta de Portugal. A pesquisa cita e discute os trabalhos relacionados, classificados por abordagens técnicas. A solução é demonstrada com etapas bem definidas tanto do ponto de vista científico quanto do ponto de vista metodológico. É utilizada uma visão científica positivista, com análise racional e qualitativa de dados experimentais, coletados de sistemas de informação e aplicados a um ambiente já operacional. A pesquisa é avaliada em termos de revocação (*recall*) e precisão da análise algorítmica de sentimentos, confrontada com sentimentos classificados de forma qualitativa por humanos. As conclusões apontam que o método de análise combinada da polaridade de sentimento é válido para efetuar medidas precisas de polaridade de sentimento no ambiente *MOOC* e que não existe relação direta entre a polaridade de sentimento e o aproveitamento acadêmico dos participantes em *MOOC* da Universidade Aberta de Portugal.

Palavras-chave: *Learning Analytics*; *MOOC*; Análise de Sentimento.

Abstract

Writing is a way of recording human expression. During writing, facts and opinions are expressed and stored in information systems. E-learning platforms are educational environments of distance learning and examples of information systems that store facts and opinions. A specific case of e-learning environment is the MOOC (Massive Open Online Course). The objective of this research is to combine four sentiment analysis API (Application program interface), described by Amazon Natural Language, Google Natural Language, IBM Watson Natural Language Understanding, and Microsoft Text Analytics to create a weighted average of these API scores to analyze the polarity of sentiments in a MOOC environment. Another objective of this research is to study if exists the relationship between the polarity of sentiment expressed in the online interventions and the academic achievement of the participants in the Universidade Aberta de Portugal.. The research cites and discusses the related works, classified by technical approaches. The solution is demonstrated with well-defined steps from both the scientific and methodological point of view. A positivist scientific view is used, with rational and qualitative analysis of experimental data, collected from information systems and applied to an already operational environment. The research is evaluated in terms of recall and precision of the algorithmic sentiment analysis, confronted with sentiment classified qualitatively by humans. The conclusions indicate that the combined polarity of sentiment analysis method is valid for performing accurate polarity of sentiment measurements in the MOOC environment and there is no direct relationship between polarity of sentiment and academic achievement of participants from Universidade Aberta de Portugal MOOC's

Keywords: Learning Analytics; MOOC; Sentiment Analysis.

Agradecimentos

Agradeço à minha família: Monique, Rapha e Lucas, pela compreensão, carinho e apoio.

Agradeço ao meu orientador, Professor Doutor Vítor Jorge Ramos Rocio, pela confiança em mim depositada e pela valiosa orientação.

Agradeço à Universidade Aberta de Portugal, na forma de todo o seu corpo funcional, pela oportunidade oferecida.

Este texto está escrito em português do Brasil, utilizando a terminologia, sintaxe e ortografia mais usuais naquele país.

Índice.

1. Introdução.....	14
1.1. Proposta e motivação para o trabalho.....	16
1.2. Questões de pesquisa.....	17
1.3. Objetivos do trabalho.....	17
1.4. Contribuições do trabalho.....	18
1.5. Organização do trabalho.....	18
2. Enquadramento teórico.....	20
2.1. <i>Learning Analytics</i>	20
2.2. A análise de sentimento.....	21
2.2.1. Abordagens baseadas em léxico.....	24
2.2.2. Abordagens baseadas em aprendizado de máquina.....	24
2.2.3. Abordagens híbridas.....	25
3. Trabalho Relacionado.....	26
4. Metodologia.....	30
4.1. Design Science Research.....	30
4.2. Desenvolvimento.....	34
4.2.1. As APIs utilizadas na pesquisa.....	34

4.2.1.1. <i>Amazon Comprehend</i>	35
4.2.1.2. <i>Google Natural Language</i>	35
4.2.1.3. <i>IBM Watson Natural Language Understanding</i>	36
4.2.1.4. <i>Microsoft Text Analytics</i>	37
4.2.2. As ferramentas utilizadas na pesquisa.....	37
4.2.3. Etapas do processo de análise do sentimento.....	38
4.2.3.1 <i>Extração e coleta</i>	39
4.2.3.2. <i>Pré-processamento</i>	41
4.2.3.3. <i>Armazenamento</i>	43
4.2.3.4. <i>Classificação</i>	44
4.2.3.5. <i>Agregação</i>	46
4.2.3.6. <i>Sumarização</i>	47
4.3. Avaliação.....	48
5. Iterações.....	51
5.1. Primeira iteração.....	51
5.1.1. O método proposto de análise combinada de sentimento.....	51
5.1.2. Avaliação e resultado da análise de sentimento na primeira iteração	52
5.2. Segunda iteração.....	52

5.2.1. O método proposto de análise combinada de sentimento.....	54
5.2.2. Avaliação e resultado da análise de sentimento na segunda iteração	54
5.3. Terceira iteração.....	55
5.3.1. O método proposto de análise combinada de sentimento.....	55
5.3.2. Avaliação e resultado da análise de sentimento na terceira iteração	56
5.4. Análise das iterações.....	58
6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante	61
7. Conclusões.....	69
8. Trabalhos futuros e considerações.....	71
9. Referências.....	77
Anexo I – Programas na linguagem <i>Python</i> desenvolvidos para a pesquisa.....	82

Índice de gráficos e tabelas.

Tabela 4.1. Exemplo de dados da tabela <i>course</i> extraídos como texto separado por tabulação (autor)....	39
Tabela 4.2: Elementos para classificação métrica das mensagens (Benevenuto, Ribeiro, & Araújo, 2015).....	49
Tabela 5.1: Total de <i>posts</i> classificados manualmente (anotados) como fato ou opinião (autor).....	51
Tabela 5.2: Total de <i>posts</i> classificados por polaridade na primeira iteração (autor).....	52
Tabela 5.3: Métricas <i>recall</i> , <i>precision</i> e <i>F1-SCORE</i> das APIs e do <i>score</i> médio na primeira iteração (autor).....	53
Tabela 5.4: Total de <i>posts</i> classificados por polaridade com <i>score</i> acima de 50% na segunda iteração (autor).....	54
Tabela 5.5: Métricas <i>recall</i> , <i>precision</i> e <i>F1-SCORE</i> das APIs e da polaridade média com scores acima de 50% na segunda iteração (autor).....	55
Tabela 5.6: Total de <i>posts</i> classificados por polaridade com polaridade média ponderada na terceira iteração (autor).....	56
Tabela 5.7: Métricas <i>recall</i> , <i>precision</i> e <i>F1-SCORE</i> das APIs e da polaridade média ponderada na terceira iteração (autor).....	57
Tabela 5.8: Exemplo de classificação efetuada pelo algoritmo de ponderação criado na terceira iteração (autor).....	57
Tabela 6.1: Quantidade de <i>posts</i> , nota média, máxima e mínima por polaridade (autor).....	62

Tabela 6.2: Quantidade de posts por estudante e percentual de conclusão médio, máximo e mínimo por polaridade (autor).....	64
Tabela 6.3: Quantidade de posts por estudante, MOOC Migrações forçadas e refugiados e respectiva nota média, máxima e mínima por polaridade (autor).....	65
Tabela 6.4: Quantidade de <i>posts</i> por estudante, <i>MOOC</i> A Biblioteca Escolar e o Desenvolvimento das Literacias e respectivo percentual de conclusão médio, máximo e mínimo por polaridade (autor)...	67
Gráfico 5.1: Relação entre as métricas e as iterações (autor).....	59
Gráfico 6.1: Estudantes e notas por polaridade positiva de sentimento (autor).....	63
Gráfico 6.2: Estudantes e notas por polaridade negativa de sentimento (autor).....	63
Gráfico 6.3: Estudantes e percentual de conclusão por polaridade positiva de sentimento (autor).....	65
Gráfico 6.4: Estudantes e notas do <i>MOOC</i> Migrações Forçadas e Refugiados por polaridade positiva de sentimento (autor).....	66
Gráfico 6.5: Estudantes e notas do <i>MOOC</i> Migrações Forçadas e Refugiados por polaridade negativa de sentimento (autor).....	67
Gráfico 6.6: Estudantes e percentual de conclusão do <i>MOOC</i> A Biblioteca Escolar e o desenvolvimento das Literacias por polaridade positiva de sentimento (autor).....	68

Índice de figuras.

Figura 2.1: Classificação das abordagens técnicas para análise de sentimentos (Santos et al., 2017).....	23
Figura 4.1: Etapas da condução da Design Science Research, segundo Takeda et al. (1990).....	32
Figura 4.2: Etapas da design science research com vários casos de estudo e iterações (Herselman & Botha, 2015).....	32
Figura 4.3: Etapas da design science research aplicadas à pesquisa (autor).....	33
Figura 4.4: Instanciação das etapas da Design science research no contexto da pesquisa.....	33
Figura 4.5: Portas e status dos nós na ferramenta KNIME (KNIME Quickstart Guide, 2018).....	38
Figura 4.6: Tabelas cujos dados foram extraídos do ambiente Moodle e SGBD MySql (autor).....	40
Figura 4.7: Coleta e armazenamento dos dados dos cursos (autor).....	40
Figura 4.8: Coleta e armazenamento dos dados dos foruns (autor).....	40
Figura 4.9: Coleta, pré-processamento e armazenamento dos dados dos estudantes (autor).....	41
Figura 4.10: Coleta, pré-processamento e armazenamento dos dados das notas dos estudantes (autor)....	42
Figura 4.11: Coleta, pré-processamento e armazenamento dos dados dos posts (autor).....	42
Figura 4.12. Coleta, pré-processamento e armazenamento dos dados de completude das atividades (autor).....	43
Figura 4.13: Diagrama da base de dados da pesquisa (autor).....	44

Figura 4.14: Normaliza os scores da API Microsoft Azure (autor).....	45
Figura 4.15: Normaliza os scores da API Amazon Comprehend (autor).....	45
Figura 4.16: Cria a média a partir dos scores normalizados gerados pelas APIs (autor).....	46
Figura 4.17: Cria a polaridade de sentimento a partir do score médio (autor).....	46
Figura 4.18: Efetua a sumarização da polaridade média por estudante (autor).....	47
Figura 4.19: Efetua a sumarização da polaridade média por estudante e MOOC (autor).....	48

1. Introdução.

1. Introdução.

Vivemos num mundo de dados e informação. Os dados são gerados, processados, visualizados e analisados em praticamente todas as áreas do conhecimento humano. A partir da utilização das Tecnologias da Informação e da criação da *Internet*, a rede de computadores global, que conecta dispositivos digitais ao redor do mundo, os dados espalharam-se e tornaram-se acessíveis a uma grande parcela da população, em grande quantidade. Com o desenvolvimento de tecnologias como a *World Wide Web* e a posterior explosão das redes sociais, os registros da expressão humana (imagens, voz e vídeo) foram facilitados por meio da digitalização destes dados. A tendência é que cada vez mais a expressão humana esteja disponível e acessível ao simples toque dos dispositivos de tecnologia da informação (Aggarwal, 2015). Uma forma de registro da expressão humana é a escrita. Nesse aspecto, dados textuais, que são registros da expressão humana no formato escrito, são passíveis de digitalização, processamento e análise. Durante a utilização de técnicas e ferramentas que interagem sobre estes dados textuais organizados por meio de **coleções de documentos** são gerados padrões e informações úteis para a solução dos mais variados problemas (Feldman & Sanger, 2007).

Segundo (Liu, 2010), existem dois tipos de informação textual possíveis de serem categorizados, e consequentemente, armazenados em dispositivos de tecnologia da informação: **fatos e opiniões**. Os fatos e opiniões incidem sobre objetos do nosso mundo, reais ou imaginários, como indivíduos, entidades, eventos e suas propriedades. Os fatos são expressões objetivas e as opiniões são expressões subjetivas, que exprimem sentimentos e avaliações sobre os objetos em foco. Por exemplo, a expressão textual que representa o ano de fabricação de determinado automóvel é um fato, ao passo que a expressão textual que representa a avaliação sobre o conforto deste mesmo automóvel é uma opinião. Até recentemente, os esforços na solução de problemas relativos ao processamento de dados textuais digitalizados se concentrava na obtenção e conhecimento de informações factuais, como por exemplo: recuperação, extração e pesquisa de dados na *World Wide Web* e classificação e agrupamento de dados textuais estruturados. O cenário tem se modificado,

1. Introdução.

de forma que as atenções se voltam para as opiniões, por serem consideradas importantes no contexto atual, diante da necessidade constante de tomadas de decisão, tanto no nível pessoal quanto profissional.

Este cenário, conforme citado anteriormente, experimentou um crescimento exacerbado com o aparecimento da *World Wide Web* e a possibilidade de registro textual das opiniões e sentimentos dos usuários (Liu, 2010). Dentre as várias possibilidades criadas com a união entre as Tecnologias da Informação e a Internet se encontra o ensino à distância. O ambiente de aprendizagem online possibilita várias interações entre os participantes, com o registro da expressão humana por meio da escrita. Os fóruns educacionais são dispositivos que permitem a interação entre os participantes de uma iniciativa de ensino à distância por meio do registro textual de fatos e opiniões (Dionísio et al., 2017). Particularmente, o objetivo do trabalho de pesquisa proposto é analisar um ambiente de ensino à distância denominado MOOC (*Massive Open Online Course*). Este ambiente possui diferenças específicas relativas ao ambiente tradicional de ensino à distância.

MOOCs são maiores em escala que os cursos tradicionais, não têm restrições à participação individual, são distribuídos globalmente através de uma variedade de redes, e visam revolucionar a forma como a educação acontece. Tais cursos são oferecidos em uma ampla gama de tópicos, abrangendo as Ciências Humanas, Ciências Sociais, Matemática, Engenharia, Ciência da Computação e outras disciplinas. Além disso, dezenas de universidades de ponta, incluindo instituições internacionais, oferecem um grande número de *MOOCs*. Os fatores acima mencionados, juntamente com a natureza aberta dos cursos e a falta de necessidade de presença física, atraem grande número de estudantes de várias origens (Adamopoulos, 2013).

Devido a uma característica do ambiente *MOOC*, que é o tamanho em larga escala, possibilitado por uma grande quantidade de estudantes em distribuição global e irrestrita, uma grande quantidade e disponibilidade de dados é gerada, que pode ser utilizada para a análise e entendimento tanto dos processos periféricos, relacionados com o funcionamento e gestão dos cursos, quanto dos processos centrais, relacionados com o ensino e aprendizagem dos estudantes. Estes dados são considerados a matéria-prima desta pesquisa.

1. Introdução.

1.1. Proposta e motivação para o trabalho.

O surgimento do ambiente de ensino à distância, apoiado basicamente pelas tecnologias da informação e comunicação, permitiu a criação de dados digitais sobre o ensino e aprendizagem dos estudantes. Estes dados tornaram possível tanto análises qualitativas quanto quantitativas sobre o desempenho dos estudantes, fornecendo pistas para investigações nas diversas áreas do conhecimento. Neste aspecto, baseado na característica do ensino à distância que permite uma relativização da presença física e temporal do estudante, ocorreram alguns questionamentos relativos ao sentimento expresso e sua influência no processo de aprendizagem. Conforme explica (David et al., 2014), “O estudo e compreensão de como a afetividade influencia no desenvolvimento da cognição humana tem forte impacto em contextos educacionais a distância”. A maioria dos estudos relacionados com o ensino não levam em conta o fator emocional na aprendizagem. Esta constatação toma uma dimensão maior no cenário de ensino à distância, que pressupõe sessões remotas, comprometendo parte da interação social possível nos ambientes tradicionais. Como as emoções afetam positivamente ou negativamente a aprendizagem, as pesquisas indicam que este processo seria mais eficaz se houvessem técnicas e ferramentas que permitissem mostrar e reconhecer as emoções e sentimento dos estudantes (Jaques & Viccari, 2006).

Partindo do cenário de utilização das tecnologias da informação no contexto das plataformas de ensino à distância, do surgimento do ambiente *MOOC*, do aumento do volume de dados gerados por estes ambientes (*big data*) e da necessidade de análise e entendimento destes mesmos dados com o objetivo de melhora no processo de ensino e aprendizagem (*learning analytics*), surge o contexto e motivação para a presente pesquisa.

1. Introdução.

1.2. Questões de pesquisa.

Diante do exposto, surgem questões que esta pesquisa busca verificar e responder:

- As ferramentas fornecidas pelos grandes *players* do mercado atual são adequadas para a análise do sentimento dos estudantes em fóruns de *MOOCs* ?
- A utilização de ferramentas de terceiros pode trazer vantagens competitivas e operacionais para o processo de análise de sentimento, mas os resultados são satisfatórios ?
- Como escolher a melhor ferramenta com API disponível no mercado para efetuar uma análise de sentimento com melhor precisão no ambiente *MOOC* ?
- Existem possibilidades de escolha da melhor ferramenta a partir da perspectiva dos resultados da avaliação por métricas, mas é possível e desejável um arranjo ou combinação destas ferramentas ?
- É sabido que um problema recorrente nos ambientes *MOOC* é o abandono e o baixo rendimento dos estudantes. Esta pesquisa busca identificar se existe a relação entre o abandono e o rendimento do estudante e sua expressão sentimental. É possível definir de forma direta e inequívoca uma relação entre a polaridade de sentimento do estudante e seu rendimento escolar no ambiente *MOOC* ?

1.3. Objetivos do trabalho.

O objetivo principal desta pesquisa é processar coleções de documentos representadas pelas interações dos estudantes nos fóruns educacionais em *MOOC* da Universidade Aberta de Portugal – UAb.pt para obter registros textuais da expressão de sentimentos destes estudantes. Neste sentido, a pesquisa busca analisar as ferramentas disponíveis pelos grandes *players* atuais do mercado de análise de sentimento para identificar a melhor opção em termos de ferramenta, verificando a possibilidade de utilização de um método que promova uma melhoria da precisão em relação à análise de sentimento no ambiente *MOOC*. Ademais, a pesquisa também pretende, em segundo

1. Introdução.

momento, analisar a polaridade destes sentimentos com o objetivo de verificar a existência da relação entre a polaridade (positiva, neutra ou negativa) destes sentimentos e o rendimento acadêmico dos estudantes (evasão e notas).

De forma resumida, esta pesquisa visa **verificar a melhor forma de analisar a polaridade de sentimento expressa nas intervenções online e o aproveitamento acadêmico dos participantes em MOOC da Universidade Aberta de Portugal, tendo em conta as ferramentas disponibilizadas por grandes *players*.**

1.4. Contribuições do trabalho.

As principais contribuições deste trabalho são as seguintes:

- Definir e validar um método de análise combinada da polaridade de sentimento para o ambiente *MOOC* baseado na média aritmética ponderada dos scores gerados por API (Interface de programação de aplicativo) de análise de sentimento fornecidas por grandes *players*.
- Verificar se existe uma relação direta entre a análise da polaridade de sentimento e o aproveitamento acadêmico dos participantes em *MOOC* da Universidade Aberta de Portugal.

1.5. Organização do trabalho.

Esta dissertação de mestrado está estruturada da seguinte forma: na seção 1 são apresentados a introdução, proposta, motivação, objetivos e organização do trabalho. A seção 2 apresenta o enquadramento teórico da pesquisa. A seção 3 indica os trabalhos relacionados ao tema da proposta de trabalho e suas abordagens técnicas. A seção 4 demonstra a metodologia científica e o desenvolvimento do trabalho, abordando sequencialmente todas as etapas executadas durante o processo de análise do sentimento, bem como as APIs e as ferramentas utilizadas e o método proposto de análise combinada de sentimento. A seção 5 apresenta as iterações efetuadas e as avaliações e resultados

1. Introdução.

obtidos durante o desenvolvimento da pesquisa. A seção 6 apresenta os resultados da relação entre a análise do sentimento e o aproveitamento do estudante. Na seção 7 são demonstradas as conclusões da pesquisa. Na seção 8 são apresentadas as possibilidades de trabalhos futuros e considerações sobre a análise de sentimento no ambiente *MOOC*. Finalizando, na seção 9 são listadas as referências bibliográficas e no anexo I são listados os programas na linguagem Python que foram desenvolvidos para a pesquisa.

2. Enquadramento teórico.

2. Enquadramento teórico.

Nesta seção é apresentada a base teórica que fundamenta a pesquisa. Esta seção inicia do conceito mais amplo, denominado *Learning Analytics*, encaminha para a análise de sentimento, que se situa no âmbito da técnica que deriva da mineração de textos e do processamento de linguagem natural, apresenta as APIs e finaliza com a descrição do método utilizado para efetuar a análise de sentimento proposta na pesquisa.

2.1. Learning Analytics.

A utilização das plataformas de ensino à distância permitiu a criação e acúmulo de grande quantidade de dados sobre as interações entre os estudantes e professores, criando um campo promissor para a análise destes dados e obtenção de novas visões e compreensões sobre os processos de ensino e aprendizagem. Aliado ao contexto político de normatização e padronização dos processos educacionais, surgiu, então, um novo conceito para lidar com estas questões: Learning Analytics (Gašević, Dawson, & Siemens, 2015; Siemens, 2013).

O termo pode ser definido como “mensuração, coleção, análise e relatório de dados sobre estudantes e seus contextos, com o propósito de entender e otimizar a aprendizagem e os ambientes nos quais ocorrem” (Siemens, 2013). Inicialmente, o foco de investigações relacionadas ao tema de *learning analytics* recaiu sobre os processos baseados em dados estatísticos, sobressaindo uma visão focada nos dados e no campo subordinado denominado EDM (*Educational Data Mining*), conforme informa (Ferguson, 2012). Posteriormente, o foco mudou para a perspectiva da aprendizagem, com a preocupação voltada para os estudantes e seus processos de aprendizagem e interação. Conforme cita (Gašević et al., 2015), apesar de o ambiente de ensino à distância possuir variadas formas de aprendizagem, interação e aferição do conhecimento, a ênfase das investigações recai nas informações quantitativas, em detrimento das informações qualitativas. Desta forma, as

2. Enquadramento teórico.

investigações privilegiam valorações, pontuações e indicadores de avanço em determinado curso.

Dados importantes e não estruturados, como textos obtidos de fóruns de discussões e mensagens entre participantes, podem ser utilizados com métodos de processamento de linguagem natural e mineração de texto para obter informação valiosa acerca da aprendizagem dos estudantes.

Assim, o desafio encontra-se em manipular estas informações textuais tipicamente qualitativas de forma quantitativa, em um ambiente com grande quantidade e disponibilidade de dados.

2.2. A análise de sentimento.

Conforme teoriza Liu (2012),

a análise de sentimento, também denominada de mineração de opinião, é o campo de estudo que analisa as opiniões, sentimentos, avaliações, apreciações, atitudes e emoções das pessoas em relação a entidades como produtos, serviços, organizações, indivíduos, questões, eventos, tópicos e seus atributos (Liu,2012).

Após a teorização, torna-se necessário esclarecer certos conceitos com o objetivo de equalizar o entendimento da análise de sentimento. Inicialmente, é importante diferenciar os textos objetivos e subjetivos. Os textos objetivos apresentam alguma informação factual sobre o mundo, enquanto os textos subjetivos apresentam impressões, opiniões, sentimentos, visões pessoais sobre este mesmo mundo, como explica Liu (2012). Neste momento, os termos opinião e sentimento tomam sentidos diferentes: a opinião é uma expressão humana representada textualmente que emite uma visão pessoal sobre determinado objeto do mundo, ao passo que o sentimento relaciona um estado de espírito relativo a determinada opinião ou visão deste mundo. Para este efeito, um texto com sentimento contém polaridade positiva, neutra ou negativa. Um texto subjetivo pode não expressar sentimento algum, ao passo que determinado texto objetivo pode expressar sentimento.

2. Enquadramento teórico.

Outro conceito importante para o contexto é a emoção. Segundo o argumento de Liu (2012),

as emoções estão intimamente relacionadas com os sentimentos. A força de um sentimento ou opinião é tipicamente ligada à intensidade de certas emoções, por exemplo, alegria e raiva. As Opiniões estudadas na análise de sentimento são principalmente avaliações (embora nem sempre) (...) finalmente, é preciso notar que os conceitos de emoção e opinião não são equivalentes. Opiniões racionais não expressam emoções (Liu, 2012).

A análise de sentimento pode ocorrer em três níveis de granularidade: no nível do documento, no nível de sentença e no nível de entidade e aspecto.

No nível do documento, o objetivo é classificar todo o texto, representado por um documento como uma mensagem postada em um fórum, por exemplo, em relação a um determinado contexto único de sentimento. Neste caso, presume-se que o documento expressa o sentimento relativo a uma única entidade.

No nível de sentença, o objetivo é classificar o sentimento específico de determinada sentença dentro de um documento, ou seja, em um nível de granularidade menor que no nível do documento. Utilizando o exemplo anterior, no nível de sentença será analisado o sentimento de determinada frase da mensagem postada em um fórum.

O nível de entidade e aspecto possui a granularidade mais baixa. Este nível objetiva classificar determinado objeto ou entidade e suas características ou aspectos em relação ao sentimento. Por exemplo, o nível de entidade e aspecto permite a classificação do sentimento de determinado aluno em relação ao prazo de entrega de determinado trabalho (aspecto) em uma disciplina (entidade) (Liu, 2012). Em relação às opiniões, existem as seguintes categorizações: a opinião regular, classificada em direta e indireta, a opinião comparativa e a opinião explícita e implícita. A opinião regular direta é expressa diretamente em relação a uma entidade e aspecto. A opinião regular indireta é expressa em relação a uma entidade ou aspecto, de forma indireta. A opinião comparativa é expressa em termos comparativos entre entidades ou aspectos. A opinião explícita é uma declaração subjetiva que fornece uma opinião regular ou comparativa. A opinião implícita é uma declaração objetiva, obtida a partir de um fato, que fornece uma opinião regular ou comparativa. Geralmente, opiniões explícitas são mais fáceis de identificar do que opiniões

2. Enquadramento teórico.

implícitas, por este motivo, a maioria das investigações na área prefere a utilização de opiniões explícitas (Liu, 2012).

Para facilitar o entendimento, cita-se alguns exemplos: “o professor é muito bom” (opinião direta regular); “depois que o professor explicou a matéria, consegui obter uma boa nota na prova” (opinião indireta regular); “o professor de cálculo é melhor que o professor de álgebra”, ou, “o professor de cálculo é o melhor” (opinião comparativa); “o professor de cálculo é o melhor da escola” (opinião explícita); “depois que o professor de álgebra começou a lecionar na turma, metade dos alunos desistiu do curso” (opinião implícita).

As abordagens técnicas utilizadas pelos trabalhos na área de análise de sentimentos são variadas, por referenciarem pesquisas já consolidadas nas áreas de mineração de dados (*data mining*) e processamento de linguagem natural (*natural language processing*) (Becker, 2014; Liu, 2012). A figura 2.1 ilustra a classificação das abordagens técnicas para análise de sentimentos exploradas até o momento.

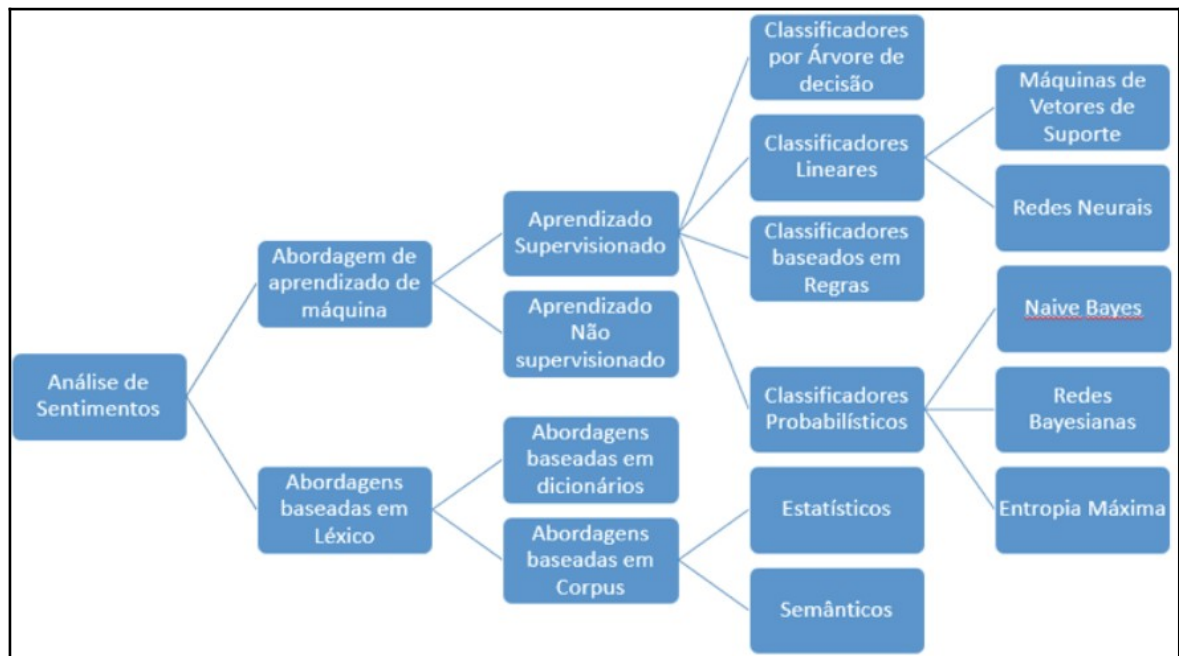


Figura 2.1: Classificação das abordagens técnicas para análise de sentimentos (Santos et al., 2017)

2. Enquadramento teórico.

2.2.1. Abordagens baseadas em léxico.

As abordagens baseadas em léxico pressupõem o uso de dicionários léxicos, que formam um conjunto de palavras existentes em determinado idioma. No contexto dos trabalhos analisados, o léxico utilizado contém um subconjunto de palavras do idioma com a semântica e polaridade voltada especificamente para a análise de sentimentos e sua classificação. Podem ser utilizados também corpus definidos para anotações e outras técnicas de processamento de linguagem natural (Santos, Silveira, & Lechugo, 2017)

2.2.2. Abordagens baseadas em aprendizado de máquina.

As abordagens de aprendizado de máquina utilizam técnicas e algoritmos baseados neste campo de pesquisa. De forma resumida, o objetivo de um algoritmo baseado em aprendizado de máquina é **aprender** uma função que, a partir de um conjunto de pares de entrada e saída de dados, forneça uma saída para novas entradas, ou de outra forma, algoritmos de aprendizagem de máquina são modelos probabilísticos que aprendem com a experiência. Neste contexto, o aprendizado pode ser supervisionado ou não supervisionado.

No aprendizado supervisionado são fornecidos exemplos de pares de entrada e saída, de forma que o algoritmo aprende a partir destes exemplos. No aprendizado não supervisionado não são fornecidos exemplos, portanto o algoritmo aprende padrões a partir da análise dos dados de entrada e de técnicas pré-definidas, como por exemplo, agrupamento (Russell, Norvig, & Davis, 2010).

2. Enquadramento teórico.

2.2.3. Abordagens híbridas.

As abordagens híbridas utilizam métodos tanto da área de léxicos quanto do aprendizado de máquina. Os trabalhos que utilizam esta abordagem seguem métodos diversos, ora alternando entre os métodos em determinadas etapas da pesquisa, ora combinando métodos nas etapas, escolhendo os mais adequados e precisos. A seção de trabalhos relacionados exemplificará alguns trabalhos que seguem esta abordagem, já que a pesquisa efetuada nesta dissertação define um método que segue uma abordagem híbrida, em certo aspecto.

3. Trabalho Relacionado.

3. Trabalho Relacionado.

Existem diversos trabalhos que tratam do tema de análise de sentimento no ambiente *MOOC*. A grande maioria dos trabalhos propõem técnicas e modelos para lidar com o problema do abandono ou evasão dos *MOOCs*, considerado alto por grande parte dos pesquisadores. Os trabalhos buscam a relação entre o sentimento e emoções dos estudantes e a possibilidade ou explicação para o abandono dos cursos ou de seu baixo rendimento. As discussões em fóruns e suas manifestações por meio de votos positivos e negativos e outras medidas são analisadas por (Feng, Chen, Zhao, Chen, & Xi, 2015; Wong, Pursel, Divinsky, & Jansen, 2015) para verificar se os estudantes mais ativos nos fóruns influenciam na performance e retenção dos cursos, bem como no rendimento acadêmico. O trabalho de Hughes & Dobbins (2015) cria um método de predição da performance do estudante em tempo real para prever a tendência e possibilidade de abandono antes da efetiva saída do curso. O Emprego do GTM (*Grounded Theory Method*) para efetuar análises quantitativas em avaliações de estudantes é a proposta de Adamopoulos (2013). São utilizadas técnicas de aprendizado de máquina, mineração de textos e econometria para criar modelos explanatórios e preditivos que explicam os fatores positivos e negativos na retenção de alunos nos cursos *MOOCs*.

O objetivo do trabalho de Rossi & Gnawali (2014) é apresentar uma ferramenta que permite à equipe de gestão do curso analisar as interações nos fóruns independentemente da linguagem e do conteúdo ensinado. Para isso, Rossi & Gnawali (2014) analisam as postagens de fóruns da plataforma *MOOC* coursera, quanto a aspectos como estrutura, suporte de redes sociais, popularidade, dinâmica de tempo e conteúdo. Utilizar as discussões no ambiente *MOOC* para extrair um vocabulário, que é definido como palavras ou frases com conteúdo implícito ou relacionado a um contexto emotivo, para verificar e prever a continuidade e permanência da participação em determinado curso *MOOC* é o objetivo do trabalho de Koutropoulos et al.(2012). Os resultados indicam que o uso de vocabulário emotivo não prediz significativamente ou impacta na retenção dos estudantes no curso. O estudo traz uma conclusão importante ao citar que as futuras pesquisas devem

3. Trabalho Relacionado.

verificar a característica de seus estudantes, separando os estudantes curiosos dos que realmente estão ativos no ambiente. O trabalho de Wen, Yang, & Rosé (2014) mostra uma correlação entre a análise de sentimento medida em postagens de fóruns e o abandono do curso, mas através de uma pesquisa qualitativa mais detalhada não observa uma influência consistente entre o sentimento expresso pelo estudante e o abandono do curso. Wen, Yang, & Rosé (2014) citam que a análise de sentimento deve ser usada com cautela, devido a ruídos nos textos e a limitação quantitativa de dados. O trabalho sugere que deve ser buscado um contexto e relação maiores entre a análise de sentimento e o curso *MOOC* a ser analisado. A proposta de Wang, Hu, & Zhou (2018) é a criação de um modelo de análise semântica *SMA* (*semantic analysis model*) e aprendizado de máquina que avalia dinamicamente as mudanças de sentimento dos estudantes com o objetivo de tratar o problema das baixas taxas de conclusão dos *MOOCs*.

Utilizar técnicas de processamento de linguagem natural e aprendizagem de máquina para analisar a motivação do estudante em textos não estruturados, e consequentemente, sua intenção em completar o *MOOC*, ao invés de questionários e avaliações com respostas fixas é a proposta de Robinson, Yeomans, Reich, Hulleman, & Gehlbach (2016). Esse trabalho cita uma limitação importante: o baixo número de estudantes para análise devido à utilização de filtros, que são necessários para a preparação dos dados. Outra conclusão interessante do trabalho de Robinson, Yeomans, Reich, Hulleman, & Gehlbach (2016) é que a análise de sentimento pode ser aplicada de forma direcionada em pesquisas de percepção dos estudantes, com perguntas e questões abertas e motivadas psicologicamente.

Assim, aproveita-se o melhor dos mundos para obter informações preciosas sobre a motivação e satisfação do aluno dentro do *MOOC*. Com a possibilidade de sistematização e rastreamento das informações dos estudantes em conjunto com perguntas abertas e direcionadas é possível prever e avaliar o sentimento do aluno e sua relação com os indicadores de eficiência do *MOOC*. O mérito do trabalho de Bergner, Kerr, & Pritchard (2015) é concluir que inferir resultados sobre a aprendizagem do estudante em *MOOC* torna-se difícil e deve ser efetuado com bastante critério devido a grande quantidade de dados faltosos e à diversidade dos participantes em *MOOC*. Assim, Bergner, Kerr, &

3. Trabalho Relacionado.

Pritchard (2015) citam alguns desafios metodológicos que devem ser abordados antes de se responder às questões principais, como, por exemplo: habilidade prévia do estudante, triagem de estudantes desmotivados, formas de lidar com as discussões e postagens.

Alguns trabalhos comparam técnicas de análise de sentimento para definirem quais são mais adequadas para a solução de determinados tipos de problema. A comparação entre algoritmos tanto de aprendizagem de máquina quanto de análise léxica é objeto do trabalho de Moreno-Marcos, Alario-Hoyos, Munoz-Merino, Estevez-Ayres, & Kloos (2018), que efetua uma análise de sentimento para a predição de padrões de retenção e engajamento de estudantes e cita dificuldades como a necessidade de classificação manual dos dados de treinamento dos algoritmos, a baixa quantidade de mensagens anotadas e a subjetividade do processo de análise de sentimento.

Outro tipo de trabalho relacionado consiste em utilizar várias abordagens combinadas, ou *ensembles*, para se chegar a um resultado mais preciso. As abordagens de análise de sentimento híbridas se enquadram neste tipo de trabalho relacionado. O trabalho de Fei & Li (2018) utiliza uma abordagem léxica denominada *word2vec* e a combina com um algoritmo de aprendizagem de máquina para análise de sentimento no fórum do ambiente MOOC e cita a dificuldade do processo, que baseia-se em uma grande carga de subjetividade e complexidade. Um modelo preditivo que utiliza a abordagem de redes neurais para efetuar as induções quanto a desistência do estudante é proposto por Chaplot, Rhim, & Kim (2015). O modelo utiliza vários parâmetros, dentre eles, o sentimento do aluno, que é obtido a partir de uma abordagem léxica. Adicionalmente, o trabalho efetua comparações entre algoritmos de classificação, avaliando os modelos em conjunto com a análise de sentimento. Para implementar um método de predição da performance do estudante, Hughes & Dobbins (2015) utilizam métodos de análise de *data warehouse*, aprendizagem de máquina e análise de redes sociais.

Finalizando, existem trabalhos cujo objetivo é utilizar várias ferramentas e efetuar uma combinação entre essas ferramentas, aumentando a precisão da análise de sentimento. O trabalho de Araújo, Gonçalves, & Benevenuto (2013) efetua uma comparação entre oito métodos de análise de sentimento e propõe um novo método para análise de sentimento baseado na combinação destes métodos comparados, denominado método combinado. Não

3. Trabalho Relacionado.

ficou claro no trabalho como é definido o método combinado. O trabalho de Araújo, Gonçalves, & Benevenuto (2013) também define o conceito de concordância, que é definido pelo grau com o qual diferentes métodos classificam a mesma polaridade em determinado conteúdo. Outro trabalho, apresentado por Chowdary, Farooq, Siddique, & Dinesh (2019) utiliza as APIs *Microsoft Text Analytics* e *Google Cloud Natural Language* para determinar o score da polaridade de sentimento de avaliações de usuários do banco de dados TMDb (*The Movie DB*). Como as avaliações dos usuários do TMDb são baseadas em uma escala de 1 (não gostei) a 5 (gostei), é utilizado um algoritmo para efetuar a normalização entre a polaridade encontrada (0 a 1) e a escala do TMDb. Apesar de usar duas APIs para a determinação da polaridade dos sentimentos, e utilizarem somente um score no algoritmo de normalização, os autores não citam como unificaram estes scores obtidos pelas duas APIs.

Finalmente, a polaridade média, ou score médio, é uma proposta metodológica efetuada por Pinto & Rocio (2019). A metodologia é baseada na média aritmética entre quatro scores gerados por APIs, nomeadamente: *Amazon Comprehend*, *Google Natural Language*, *IBM Watson Natural Language Understanding* e *Microsoft Text Analytics*. Este trabalho introdutório mostra, a partir das métricas *recall*, *precision* e *F1-score* que a utilização da metodologia aumenta a precisão das classificações de polaridade de sentimento.

4. Metodologia.

4. Metodologia.

Nesta seção é apresentada a metodologia utilizada no trabalho. A metodologia científica define as etapas e o rigor necessário para a consolidação do trabalho acadêmico.

4.1. *Design Science Research.*

O método de pesquisa define teorias e práticas para a aplicação de procedimentos e regras com o objetivo de construir, consolidar e validar o conhecimento científico. Assim, o objetivo primário da ciência é formar uma base de conhecimento contextualizada sobre objetos, fatos ou fenômenos observáveis e simuláveis no mundo, descrevendo e explicando. Esta é uma verdade para os objetos e fenômenos naturais, ou seja, para objetos e fenômenos que se encontram na natureza e que foi pensada e utilizada como uma única forma de se “fazer” ciência até determinado momento e contexto. No entanto, Simon (1996) pondera que, atualmente, nosso mundo é mais artificial e tecnológico do que natural, ou seja, sofre mais interferências e modificações humanas do que naturais.

Portanto, algumas questões relacionadas com o método científico também sofrem modificações e necessitam ser reavaliadas. Neste ponto, cabe uma separação proposta por Simon (1996): a definição de uma ciência para lidar com o “mundo natural”, ou seja, o mundo dos objetos e fenômenos encontrados na natureza, denominada **ciência do natural**, e a definição de uma ciência para lidar com o “mundo artificial”, ou seja, o mundo criado e modificado pelas mãos do ser humano, denominada **ciência do artificial**. Deve-se salientar que a separação entre as duas ciências não significa oposição e sim complemento: a ciência do artificial complementa a ciência do natural, a primeira está contida na segunda, ou de outra forma, a ciência do artificial se submete às leis da ciência natural (Simon, 1996). A partir do conceito de artefatos, que são definidos como objetos artificiais abstratos com objetivos, funções e adaptações, formulados para interagir com determinado ambiente, criando para isso uma interface, surge uma “nova” ciência e um novo método para lidar com essa ciência: a *design science* e o *design science research* (Lacerda, Dresch, Proença,

4. Metodologia.

& Antunes Júnior, 2013). Esta dissertação se enquadra nos conceitos e preceitos da ciência do artificial, à medida que trata do uso de Sistemas de Informação no contexto educativo e propõe uma análise de sentimento baseada em algoritmos de processamento de linguagem natural e aprendizagem de máquina. Assim, a metodologia utilizada será a **Design science research**. Conforme explicita Lacerda, Dresch, Proença, & Antunes Júnior (2013), as etapas de condução da *design science research* são: **conscientização, sugestão, desenvolvimento, avaliação e conclusão**. A etapa de **conscientização** é preconizada pela evidenciação da situação problema. A seção de introdução define os objetivos, motivação e organização do trabalho, enunciando o ambiente externo, atores e os possíveis pontos de interação com o artefato proposto. A etapa de **sugestão** possui relação com a etapa de desenvolvimento, à medida que propõe premissas, requisitos e registros de tentativas para o desenvolvimento de um determinado artefato, conforme citado por Lacerda, Dresch, Proença, & Antunes Júnior (2013). A partir do enquadramento teórico e dos trabalhos relacionados é possível delinear a classe de problemas a que se refere a pesquisa e a proposta de artefato a ser desenvolvido. A etapa de **desenvolvimento** diz respeito à prática metodológica do desenvolvimento da pesquisa propriamente dita, culminando com a criação do artefato. A etapa de **avaliação**, definida por Lacerda, Dresch, Proença, & Antunes Júnior (2013), “é um processo rigoroso de verificação do comportamento do artefato no ambiente para o qual foi projetado, em relação às soluções que se propôs alcançar“. No contexto deste trabalho, o objetivo da etapa de **avaliação** é verificar se o artefato fornece respostas confiáveis e aceitáveis quanto ao resultado da análise de sentimento dos estudantes baseado nos textos expressos no ambiente *MOOC*. Para isso, é proposta uma comparação, por meio de métricas, entre os resultados do algoritmo e a classificação manual da polaridade do sentimento efetuada por humanos. A seção de **conclusão** da pesquisa evidencia algumas direções e alternativas tomadas durante a etapa de sugestão, bem como suas iterações. Baseado no trabalho de Lacerda, Dresch, Proença & Antunes Júnior (2013), Takeda et al. (1990) e Herselman & Botha (2015), ilustrado nas figuras 4.1 e 4.2, foi criado um diagrama, representado na figura 4.3, que exemplifica as etapas da metodologia *design science research* aplicadas à esta investigação.

4. Metodologia.

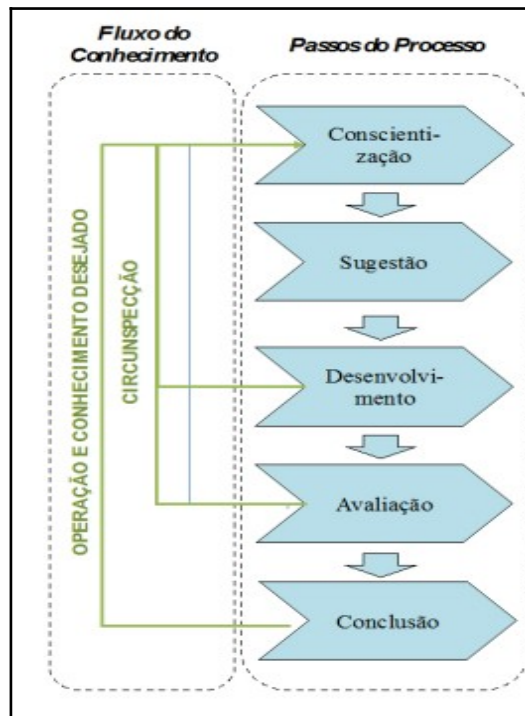


Figura 4.1: Etapas da condução da *Design Science Research*, segundo Takeda et al. (1990)

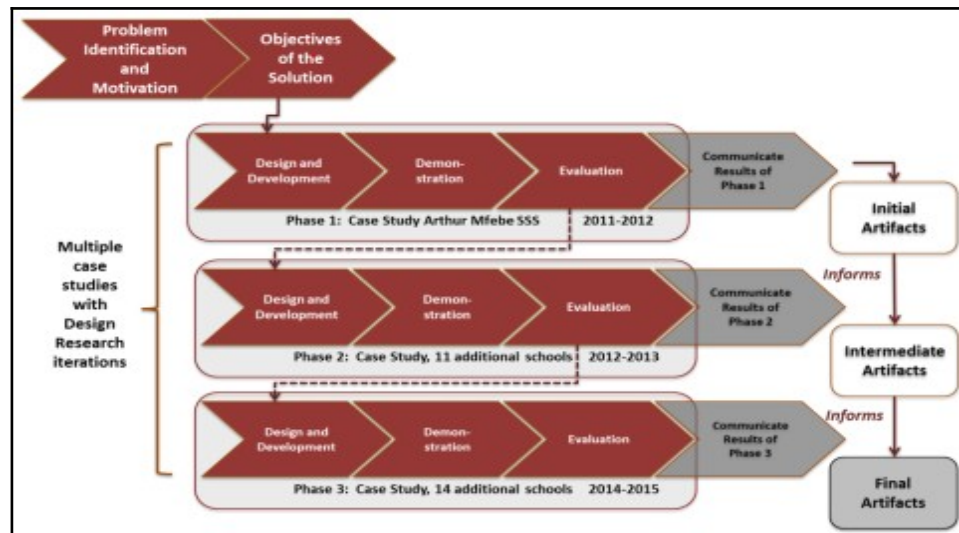


Figura 4.2: Etapas da design science research com vários casos de estudo e iterações (Herselman & Botha, 2015).

4. Metodologia.

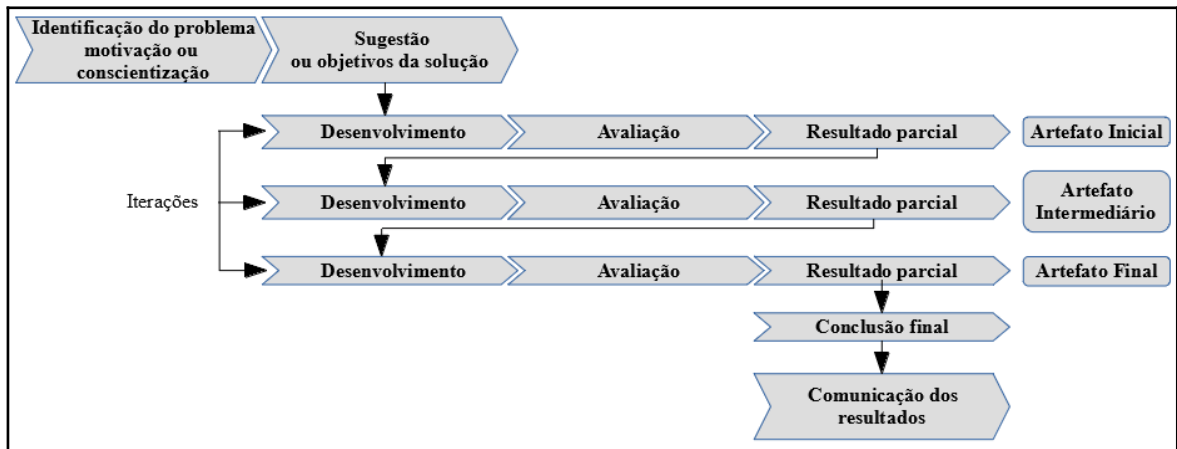


Figura 4.3: Etapas da *design science research* aplicadas à pesquisa (autor).

A partir da figura 4.3 é criada a figura 4.4, com a instanciação das etapas da *design science research* e suas iterações no contexto da pesquisa aqui apresentada.

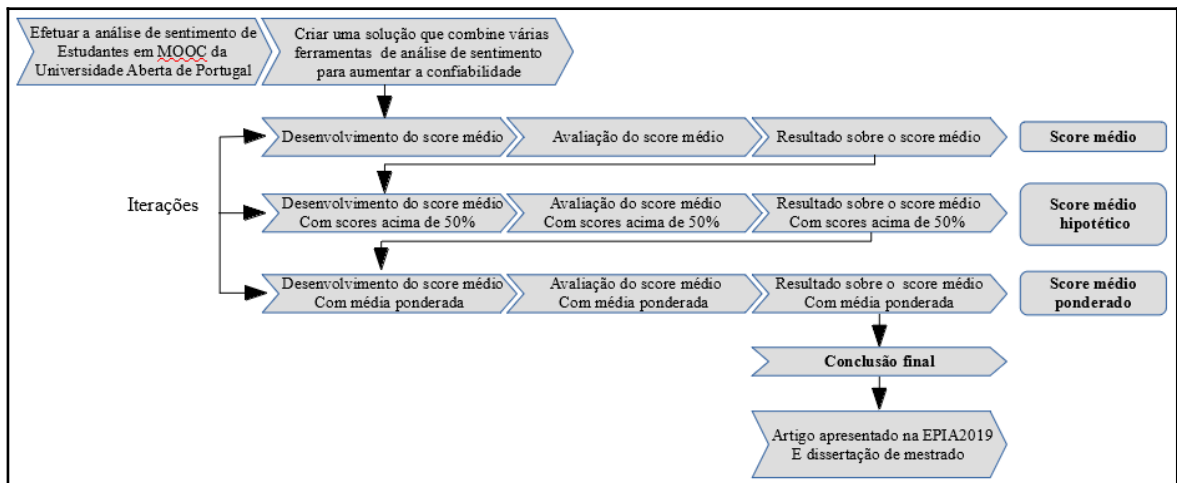


Figura 4.4: Instanciação das etapas da *Design science research* no contexto da pesquisa.

4. Metodologia.

4.2. Desenvolvimento.

A seção de desenvolvimento demonstra a prática da pesquisa, ou seja, os passos executados para a construção, execução, testes e avaliação do artefato. Esta seção enumera as ferramentas e etapas utilizadas para a geração e análise dos dados da pesquisa. A etapa de desenvolvimento da pesquisa foi definida para ser executada de forma linear e sequencial, mas devido à características da prática científica, as etapas foram executadas de forma iterativa. Assim, conforme preconiza a metodologia científica adotada (*design science research*), foram efetuadas várias iterações e sugestões de artefatos funcionais, até culminar com o artefato final e ideal para a pesquisa.

4.2.1. As APIs utilizadas na pesquisa.

O objetivo desta pesquisa é propor um método de análise de sentimento que utiliza a média aritmética dos resultados de um conjunto de ferramentas. Nesta seção são apresentadas as quatro APIs que são utilizadas para compor a combinação final de scores, que são pontuações ou percentuais indicativos da polaridade do sentimento. Do ponto de vista da metodologia, a escolha das APIs toma aspecto secundário, pois a abordagem sugerida segue o conceito *blackbox*, ou seja, esta pesquisa ignora o funcionamento interno e as técnicas utilizadas nas APIs, por ser irrelevante para o escopo da pesquisa. Os artefatos técnicos criados para a interação com as APIs serão mostrados na seção 4 – Metodologia. A escolha das APIs seguiu a orientação fornecida por (Dale, 2018), que sugere existirem quatro grandes players no mercado, apresentados a seguir. Todas as APIs utilizadas foram implementadas segundo a infraestrutura SAAS¹ e foi necessário uma inscrição preliminar para acesso aos seus serviços gratuitos.

¹ SAAS: *Software as a service*, traduzido em Software como serviço.

4. Metodologia.

4.2.1.1. Amazon Comprehend.

Conforme cita o Amazon Comprehend - Developer Guide (2019),

O Amazon Comprehend usa o processamento de linguagem natural para extrair insights sobre o conteúdo de documentos. O Amazon Comprehend processa qualquer arquivo de texto no formato UTF-8. Desenvolve insights por reconhecer as entidades, frases-chave, linguagem, sentimentos e outros elementos comuns em um documento. O Amazon Comprehend determina o sentimento emocional de um documento. O sentimento pode ser positivo, neutro, negativo ou misto. As operações retornam o sentimento mais provável para o texto, bem como as pontuações para cada um dos sentimentos. A pontuação representa a probabilidade de o sentimento ter sido detectado corretamente. Por exemplo, no exemplo abaixo, é 95% provável que o texto tenha um sentimento positivo. Existe menos de 1% de probabilidade de o texto ter um sentimento negativo. Você pode usar o `SentimentScore` para determinar se a precisão da detecção atende às necessidades do seu aplicativo (Amazon Comprehend - Developer Guide, 2019),.

```
1
2   {
3     "SentimentScore": {
4       "Mixed": 0.030585512690246105,
5       "Positive": 0.94992071056365967,
6       "Neutral": 0.0141543131828308,
7       "Negative": 0.00893945890665054
8     },
9     "Sentiment": "POSITIVE",
10    "LanguageCode": "en"
11  }
```

Código 4.1: Resultado da API Amazon Comprehend API no formato json.

4.2.1.2. Google Natural Language.

Os princípios básicos da *Google Natural Language API* (2019) informam que a

Cloud Natural Language API oferece tecnologias de compreensão de linguagem natural para desenvolvedores, incluindo análise de sentimento, análise de entidade, análise de sentimento de entidade, classificação de conteúdo e análise de sintaxe. A Análise de sentimento inspeciona o texto fornecido e identifica a opinião emocional dominante no texto, principalmente para determinar a atitude do escritor como positiva, negativa ou neutra. A análise de sentimentos determina a atitude de modo geral, positiva ou negativa, expressa no texto. Os sentimentos são representados por valores numéricos score e magnitude. A pontuação de sentimento de um documento indica a emoção de modo geral. A magnitude de sentimento de um documento indica o conteúdo emocional presente nele, e esse valor é geralmente proporcional ao tamanho do documento. Um documento com uma pontuação neutra de aproximadamente 0.0 pode indicar baixa emoção, ou indicar emoções mistas,

4. Metodologia.

com valores altamente positivos e também negativos que se anulam. Em geral, use valores de magnitude para eliminar a ambiguidade nesses casos, já que documentos verdadeiramente neutros têm um valor baixo de magnitude, enquanto documentos mistos têm valores de magnitude maiores (*Google Natural Language API*, 2019).

```
1  {
2  "documentSentiment": {
3  "score": 0.2,
4  "magnitude": 3.6
5  },
6  "language": "en",
7  }
```

Código 4.2: Resultado da API Google Natural Language API no formato json.

4.2.1.3. IBM Watson Natural Language Understanding.

Com o trabalho de Vergara, El-Khouly, Tantawi, Marla, & Sri (2017),

os desenvolvedores podem analisar os recursos semânticos de um texto e extrair metadados do conteúdo, como categorias, conceitos, emoção, entidades, palavras-chave, metadados, relações, papéis semânticos e sentimento. O *Natural Language Understanding* pode ser útil em muitos cenários que exigem uma análise rápida do texto não estruturado, sem a necessidade de conhecimento aprofundado do processamento de linguagem natural. Por exemplo, você pode monitorar o sentimento e a emoção nas transcrições de bate-papo do suporte ao cliente ou pode categorizar rapidamente as postagens do blog e classificá-las com base em conceitos gerais, palavras-chave e entidades. O recurso Sentimento da NLU identifica atitudes, opiniões ou sentimentos no conteúdo que está sendo analisado. Você pode usar esse recurso para analisar o sentimento em relação a frases-alvo específicas ou informações sobre entidades e palavras-chave detectadas, ativando a opção de sentimento para esses recursos. Como resposta a API retorna, dentre outros parâmetros, o label, que indica se o sentimento é positivo, neutro ou negativo e a pontuação de sentimento que varia de -1 (sentimento negativo) a 1 (sentimento positivo) (Vergara, El-Khouly, Tantawi, Marla, & Sri, 2017).

```
1  "document": {
2  "score": 0.127034,
3  "label": "positive"
4  }
```

Código 4.3: Resultado da API IBM Watson Natural Language Understanding no formato json.

4. Metodologia.

4.2.1.4. Microsoft Text Analytics.

Segundo *Sentiment analysis using the Text Analytics from Azure Cognitive Services - Microsoft docs* (2019),

A API de Análise de Texto é um serviço baseado em nuvem que fornece um processamento de idioma natural avançado sobre texto bruto e inclui quatro funções principais: análise de sentimento, extração de frases-chave, detecção de idioma e reconhecimento de entidade. A Análise de Sentimento pode ser usada para descobrir o que os clientes pensam da marca ou tópico, analisando texto bruto em busca de pistas sobre sentimentos positivos ou negativos. Essa API retorna uma pontuação de sentimento entre 0 e 1 para cada documento, em que 1 é a mais positiva. Os modelos de análise são pré-treinados usando um amplo corpo de texto e tecnologias de idioma natural da Microsoft (*Microsoft docs*, 2019)

```
1  {'documents': [{'id': '1', 'score': 0.7673527002334595},
2                        {'id': '2', 'score': 0.18574094772338867},
3                        {'id': '3', 'score': 0.5}],
4  'errors': []}
```

Código 4.4: Resultado da API Microsoft Text Analytics no formato json.

4.2.2. As ferramentas utilizadas na pesquisa.

As ferramentas utilizadas durante o processo de desenvolvimento e análise da pesquisa são consideradas Software Livre, excetuando-se as APIs já mencionadas, cujos respectivos desenvolvedores possuem seus direitos de propriedade. Para os processos de coleta e pré-processamento dos dados foi utilizada a ferramenta KNIME², em conjunto com códigos desenvolvidos na linguagem Python³. O sistema gerenciador de banco de dados utilizado para o armazenamento dos dados da pesquisa é o Postgresql⁴. Foi utilizada também a ferramenta Libreoffice⁵ para a escrita dos textos e geração dos gráficos da dissertação. Como a ferramenta KNIME foi utilizada em grande parte da pesquisa, e seus

2 <https://www.knime.com/>

3 <https://www.python.org/>

4 <https://www.postgresql.org/>

5 <https://www.libreoffice.org/>

4. Metodologia.

fluxos de trabalho serão ilustrados na dissertação, é necessário um maior entendimento de seu funcionamento. Conforme informa o KNIME Quickstart Guide (2018),

na plataforma analítica KNIME as tarefas individuais são representadas por nós. Cada nó é exibido como uma caixa colorida com portas de entrada e saída, bem como um status, conforme mostrado na Figura 4.5. A (s) entrada (s) são os dados que o nó processa e as saídas são os conjuntos de dados resultantes. Cada nó tem configurações específicas, que podemos ajustar em um diálogo de configuração. Quando fazemos isso, o status do nó muda, mostrado por um semáforo abaixo de cada nó. Os nós podem executar todos os tipos de tarefas, incluindo a leitura e gravação de arquivos, transformação de dados, treinamento de modelos, criação de visualizações e assim por diante. Uma coleção de nós interconectados constitui um fluxo de trabalho e geralmente representa uma parte, ou todas, de um projeto particular de análise de dados (KNIME Quickstart Guide, 2018).

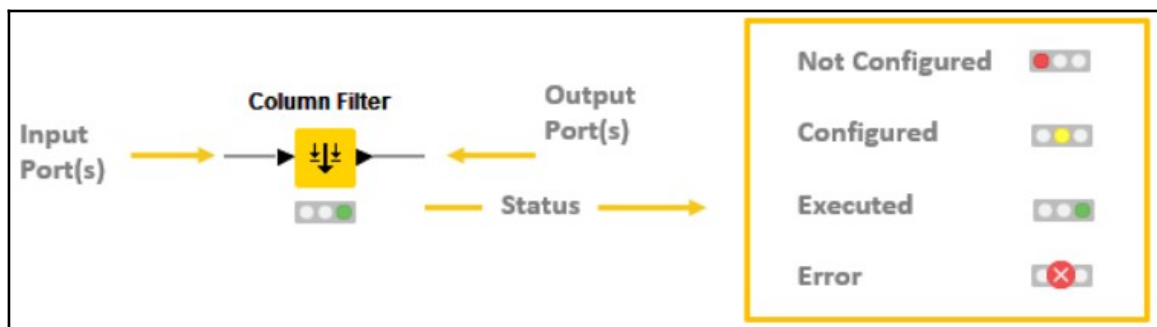


Figura 4.5: Portas e status dos nós na ferramenta KNIME (KNIME Quickstart Guide, 2018)

4.2.3 Etapas do processo de análise do sentimento.

O trabalho de Tsytsarau & Palpanas (2012) enumera, em aspecto geral, os passos encontrados em grande parte das técnicas e métodos de análise de sentimento utilizadas atualmente: identificação, classificação e agregação. Esta pesquisa segue o mesmo modelo, com a definição de etapas intermediárias, como as etapas de extração e coleta, pré-processamento e armazenamento. As etapas foram definidas e executadas em uma sequência linear, mas, como citado anteriormente, ocorreram interações e houve a necessidade de correções e execução de etapas anteriores.

4. Metodologia.

4.2.3.1 Extração e coleta.

Os dados utilizados na pesquisa foram extraídos e coletados da ferramenta Moodle⁶, que é o software utilizado nos ambientes *MOOC* da AulAberta. Estes dados estão armazenados no sistema gerenciador de banco de dados MySQL⁷, e foram extraídos no formato de texto puro, separado por colunas (tabela 4.1). As tabelas extraídas foram: **user**, **course**, **course_modules**, **course_modules_completion**, **fórum**, **forum_discussions**, **forum_posts**, **grade_grades**, **grade_items** (figura 4.6).

id	category	sortorder	fullname
2	3	40012	Conhecer o Agrinho
4	2	20012	Onde Estão as Raízes?
5	4	30014	Introdução à Informática
10	2	20010	Lisboa, Cidade Aberta
11	2	20009	Caminhos para a Gestão Moderna
12	2	20007	As Humanidades no Mundo de Hoje: da Tradição à Modernidade
13	2	20011	EUROPA, Presente, Futuro
14	2	20008	O Ambiente Já Não Está na Moda?
15	2	20006	Introdução à Estatística: Estatística Descritiva com R
16	2	20005	Geometria das Ilusões de Ótica
17	2	20004	Educar para Transformar: Missão Possível?
18	4	30011	Competências Digitais para Professores
19	4	30012	Alterações Climáticas: O Contexto das Experiências de Vida
20	2	20003	Línguas Vivas Estrangeiras
23	4	30010	A Biblioteca Escolar e o Desenvolvimento das Literacias
24	4	30009	O Real Paço Mafra: do Magnânimo ao Clemente
25	3	40011	Ecologia Industrial
26	3	40010	Morcegos, os Senhores da Noite
27	3	40009	O que a Ciência nos diz sobre as Alterações Climáticas
28	2	20002	Alexandre Magno - Um Homem que Mudou o Mundo
30	4	30008	O Património Ibérico Classificado pela Unesco. Estudos de caso: Toledo e Évora

Tabela 4.1. Exemplo de dados da tabela *course* extraídos como texto separado por tabulação (autor).

⁶ <https://moodle.org/>

⁷ <https://www.mysql.com/>

4. Metodologia.

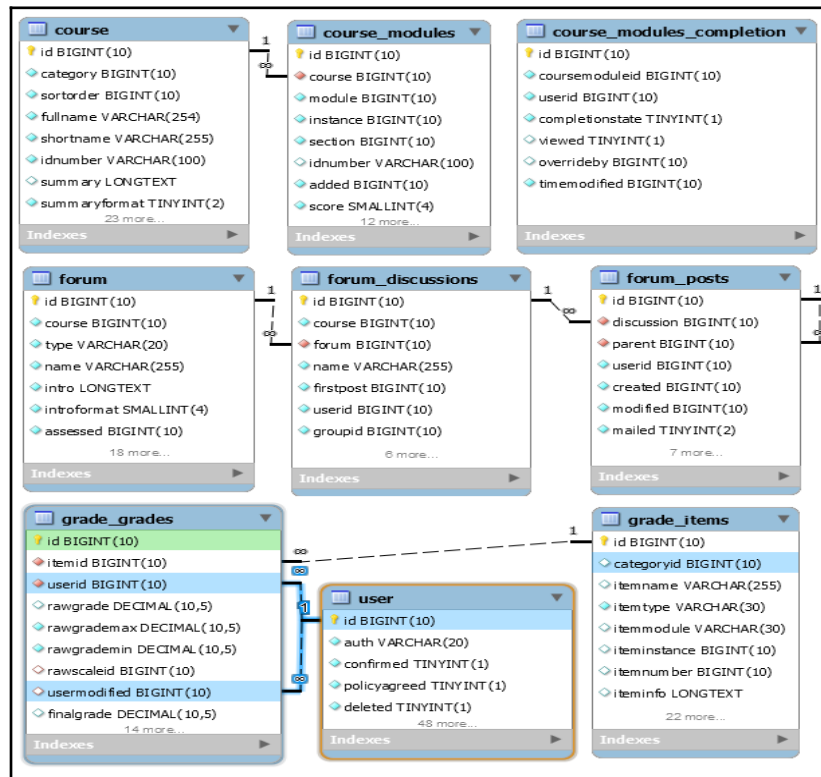


Figura 4.6: Tabelas cujos dados foram extraídos do ambiente Moodle e SGBD MySQL (autor).

Não foi necessário nenhum pré-processamento nos dados dos cursos e fóruns. Os dados foram coletados e armazenados diretamente na base de dados da pesquisa, conforme ilustra a figura 4.7 e a figura 4.8.




Figura 4.7: Coleta e armazenamento dos dados dos cursos (autor).




Figura 4.8: Coleta e armazenamento dos dados dos fóruns (autor).

4. Metodologia.

Imediatamente após a coleta é efetuado o pré-processamento dos dados, seguindo o próprio fluxo de trabalho da ferramenta KNIME, como demonstrado abaixo.

4.2.3.2. Pré-processamento.

Durante a etapa de pré-processamento é necessário efetuar algumas modificações e correções nos dados coletados do ambiente *MOOC* AulAberta, pois alguns dados não estão em conformidade com todas as premissas da pesquisa. Portanto, após as coletas de dados dos estudantes como notas, mensagens dos fóruns (*posts*) e das atividades e seu percentual de conclusão foi necessário efetuar tarefas de pré-processamento para adequação destes dados. Todos os pré-processamentos são detalhados a seguir: após a coleta dos dados dos estudantes é efetuado um pré-processamento para verificação da sua situação. Caso o estudante não esteja ativo na base de dados, conseqüentemente, no ambiente *MOOC* AulAberta, é criado um atributo denominado status que indica se o estudante está ativo ou não no ambiente *MOOC*, como ilustra a figura 4.9. Em relação aos dados pessoais do estudante, foi tomado o cuidado de se manter o anonimato. Somente o identificador numérico do estudante e sua situação cadastral é armazenada na base de dados da pesquisa.




Figura 4.9: Coleta, pré-processamento e armazenamento dos dados dos estudantes (autor).

Após a coleta e pré-processamento dos dados do estudante, é efetuada a coleta e pré-processamento dos dados das notas dos estudantes. As notas são coletadas das tabelas *grade* e *grade items*. Após a coleta é efetuado o pré-processamento com a união (nó *joiner*) e a normalização das notas (nó *math formula*), como mostrado na figura 4.10. A

4. Metodologia.

normalização das notas é necessária pois as diversas atividades dos estudantes nos cursos possuem valores diferenciados. Assim, após o processamento, as notas indicam o percentual de sucesso do aluno nas respectivas atividades.

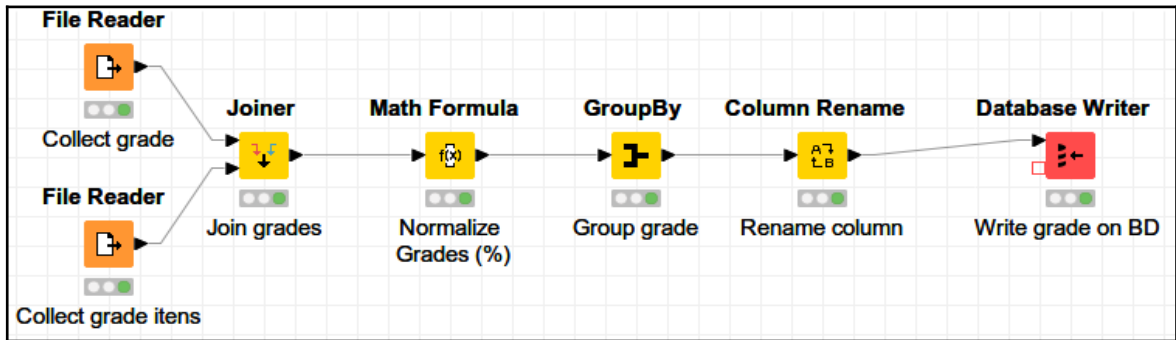


Figura 4.10: Coleta, pré-processamento e armazenamento dos dados das notas dos estudantes (autor).

A coleta dos *posts*, ou mensagens, conforme mostra a figura 4.11, é efetuada e a etapa de pré-processamento tem início com o objetivo de remover marcações (*tags*) *HTML* (*Hyper text markup language*) das mensagens, deixando apenas os textos escritos em língua portuguesa. É efetuada também a remoção de mensagens com menos de trinta caracteres de tamanho. É suposto que mensagens com menos de 30 caracteres de tamanho não possuem elementos textuais suficientes para a verificação da expressão de sentimentos.




Figura 4.11: Coleta, pré-processamento e armazenamento dos dados dos *posts* (autor).

Após a coleta das mensagens dos estudantes é efetuada a coleta de dados de acompanhamento e andamento dos cursos. Esta etapa é necessária pois alguns módulos dos cursos não possuem valoração por notas, bastando verificar se o estudante terminou os módulos. A coleta é efetuada na tabela *course_modules_completion*. Aqui também é

4. Metodologia.

necessário efetuar uma normalização, já que os dados coletados somente indicam se os estudantes completaram ou não os módulos. Neste caso, é efetuada uma contagem dos módulos finalizados e não finalizados, e obtido um percentual que representa a finalização dos módulos (figura 4.12).

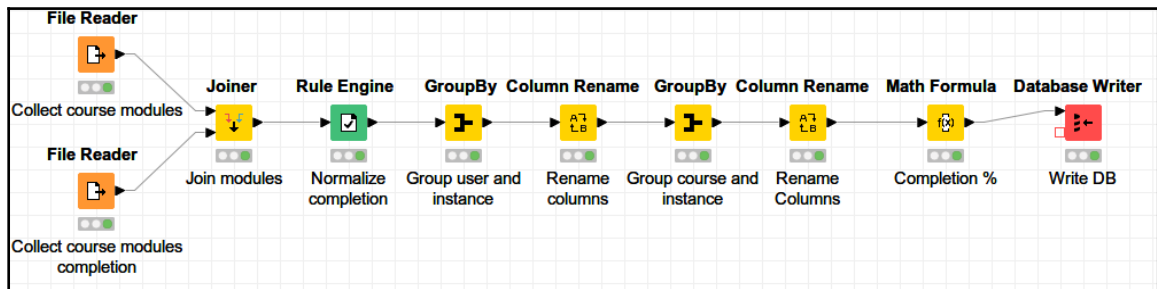


Figura 4.12. Coleta, pré-processamento e armazenamento dos dados de completude das atividades (autor).

Após a coleta e pré-processamento, os dados modificados são armazenados em uma base relacional que foi criada especificamente para auxiliar a pesquisa.

4.2.3.3. Armazenamento.

Os dados coletados e pré-processados são armazenados em uma base relacional criada no SGBD PostgreSQL para facilitar sua posterior manipulação. A base criada para auxiliar a pesquisa é ilustrada na figura 4.13. Os dados coletados das tabelas do ambiente Moodle com os cursos *MOOC* são relacionados com as seguintes tabelas criadas para a pesquisa (figura 4.13): Os dados da tabela **user** são armazenados na tabela **estudante**; os dados da tabela **course** são armazenados na tabela **MOOC**; os dados da tabela **course_modules** e **course_modules_completion** são armazenados na tabela **conclusão**; os dados da tabela **fórum**, **forum_discussions** e **forum_posts** são armazenados nas tabelas **fórum** e **mensagem**; os dados das tabelas **grade_grades**, **grade_items** são armazenados na tabela **nota**.

4. Metodologia.

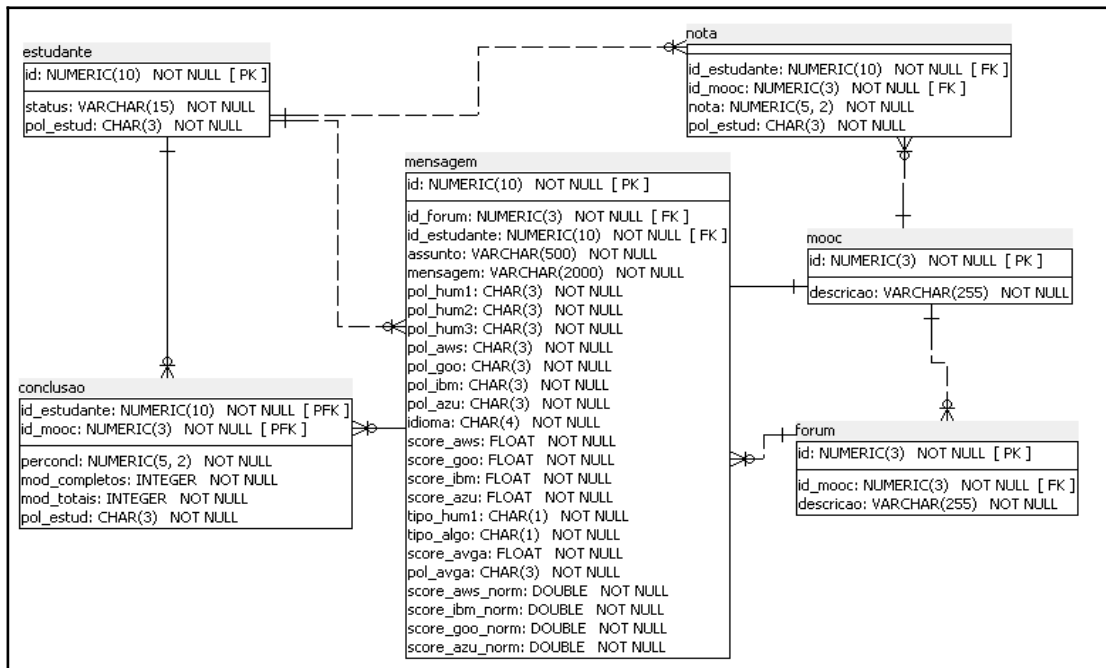


Figura 4.13: Diagrama da base de dados da pesquisa (autor).

4.2.3.4. Classificação.

A etapa de classificação corresponde ao processo de análise da polaridade do sentimento das mensagens dos estudantes. Foram criados quatro programas na linguagem Python (anexo 1) para efetuar a conexão com as quatro APIs já referenciadas e obter as polaridades de sentimento de cada mensagem, gravando os resultados na base de dados da pesquisa. Após a obtenção da polaridade de sentimento e score de cada API, é necessário efetuar uma normalização dos *scores* de duas APIs: *Microsoft Azure* e *Amazon Comprehend*. Conforme já citado no item 4.2.1.4, o score gerado como resultado pela API *Microsoft azure* situa-se entre 0 e 1, indicando 0 o *score* mais negativo e 1 o *score* mais positivo. O objetivo da normalização do score gerado pela API *Microsoft Azure* é passar este *score* para o padrão -1 a +1, onde -1 é o *score* mais negativo e +1 é o *score* mais positivo. A normalização da API *Microsoft Azure* é ilustrada na figura 4.14.

4. Metodologia.




Figura 4.14: Normaliza os scores da API Microsoft Azure (autor).

O resultado do *score* gerado pela API *Amazon Comprehend*, citada no ítem 4.2.1.1, retorna valores entre 0 e 1, onde a polaridade é definida pelo rótulo, ou seja, se o *score* retornar 1 e o rótulo retornar “NEGATIVE”, indica que o texto avaliado possui alta polaridade negativa (*score* -1). A normalização da API *Amazon Comprehend* é ilustrada na figura 4.15. Neste caso, o processo de normalização vai atribuir o sinal positivo ou negativo ao *score* gerado pela API *Amazon Comprehend*, de acordo com o rótulo da polaridade de sentimento.




Figura 4.15: Normaliza os scores da API Amazon Comprehend (autor).

Para normalizar o *score* gerado pela API *Amazon Comprehend* é utilizado um cálculo simples que converte o valor do *score* para um valor negativo caso o resultado da polaridade seja negativo (II).

$$\text{Score Negativo Normalizado} = \text{SCORE} * (-1) \quad (\text{II})$$

Em relação à normalização do *score* da API *Microsoft Text Analytics*, é utilizado o cálculo proposto em (III) e (IV) para converter o valor do *score* gerado para o valor normalizado.

$$\text{Score Negativo Normalizado} = (0.5 - \text{SCORE}) * (-2) \quad (\text{III})$$

4. Metodologia.

$$\text{Score Positivo Normalizado} = (\text{SCORE} - 05) * (2) \quad (\text{IV})$$

Após o processo de classificação, cujo objetivo é obter os resultados das classificações de polaridade dos sentimentos das quatro APIs analisadas e normalizar os *scores*, é necessário desenvolver um método para combinar os resultados normalizados das APIs em um único *score*, que definirá a polaridade de sentimento do post analisado.

4.2.3.5. Agregação.

Esta etapa tem como objetivo agregar ou unificar os *scores* gerados pelas quatro APIs em um único score que representará a polaridade de sentimento do *post* analisado, conforme citado por Pinto & Rocio (2019). Foi definido um método, conforme demonstrado na seção 4, que consiste em obter a média aritmética dos *scores* gerados pelas quatro APIs, e a partir deste score médio, definir também uma polaridade média. Este método será definido com detalhes na seção 5, onde ocorrerão as iterações. A figura 4.16 ilustra a etapa de cálculo do *score* médio com a utilização da ferramenta KNIME.




Figura 4.16: Cria a média a partir dos *scores* normalizados gerados pelas APIs (autor).

Após o cálculo e armazenamento do *score* médio é efetuado o cálculo da polaridade do sentimento, conforme mostra a figura 4.17, que consiste em verificar se o *score* indica um sentimento negativo, neutro ou positivo.




Figura 4.17: Cria a polaridade de sentimento a partir do *score* médio (autor).

4. Metodologia.

4.2.3.6. Sumarização.

A etapa de sumarização promove uma verificação da polaridade de cada *post* do estudante em determinado *MOOC* e sumariza uma única polaridade que será definida para este estudante no *MOOC*, para posterior verificação da relação com a sua performance. É também efetuada uma sumarização geral da polaridade do estudante, independente do *MOOC* cursado. A definição da polaridade de sentimento sumarizada é conseguida com a utilização de uma escala de -1,0,1, indicando respectivamente, a polaridade negativa, neutra e positiva, admitindo valores positivos como polaridade positiva, o valor zero como polaridade neutra e valores negativos como polaridade negativa. Por exemplo, se determinado estudante possui três *posts* classificados pela polaridade média como neutro (0), positivo(+1) e positivo (+1), sua polaridade sumarizada é positiva, pois a soma da escala é +2. Outro exemplo, se determinado estudante possui apenas dois *posts*, classificados pela polaridade média como negativo (-1) e positivo (+1), será assumido pela pesquisa que a polaridade sumarizada deste estudante é neutra, pois a soma das polaridades na escala é 0. Se o estudante possuir apenas um *post*, a sua polaridade será definida pela polaridade média de seu único *post*. A figura 4.18 ilustra o processo de sumarização da polaridade média por estudante e a figura 4.19 mostra o processo de sumarização da polaridade média dos estudantes por nota e por conclusão de módulos, atividades e tarefas.

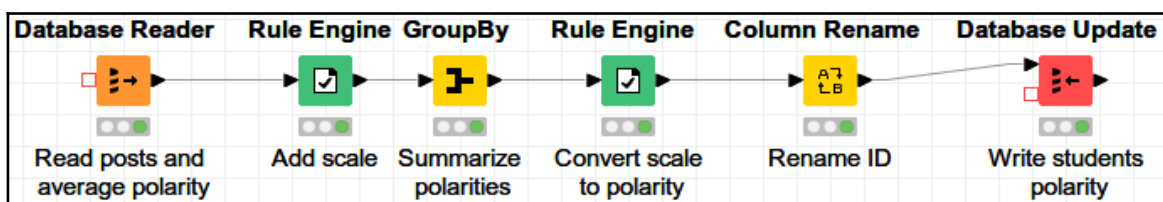


Figura 4.18: Efetua a sumarização da polaridade média por estudante (autor).

4. Metodologia.

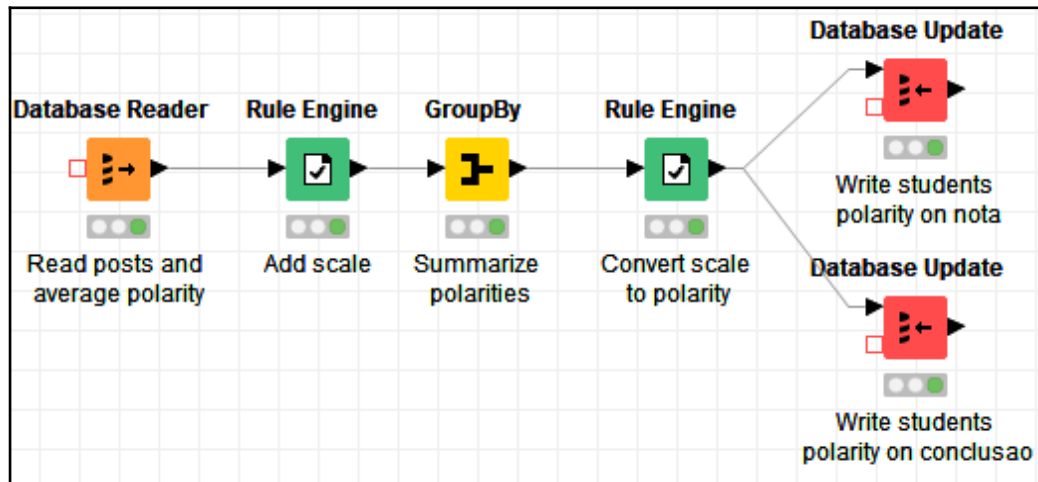


Figura 4.19: Efetua a sumarização da polaridade média por estudante e MOOC (autor).

Estas relações entre a polaridade média dos estudantes e seus indicadores de aproveitamento, como notas e percentual de conclusão de atividades, serão analisados posteriormente na seção 6.2.

4.3. Avaliação.

A etapa de avaliação consiste em verificar as métricas e comparar a polaridade de sentimento classificada pelos algoritmos. Para o efeito, foram efetuadas previamente análises qualitativas com intervenção humana em todas as mensagens contidas na base de dados da pesquisa. Na etapa de avaliação são utilizadas métricas já consagradas pela disciplina de Recuperação da Informação e utilizadas na análise de sentimento, como revocação (*recall*), precisão e F1-score. Segundo informa Benevenuto, Ribeiro, & Araújo (2015), as métricas precisão e revocação, bem como F1-score, que é a média harmônica das duas métricas anteriores, são eficazes para medir o sucesso de um método na predição da polaridade de sentenças.

4. Metodologia.

		Predição		
		Positiva	Neutra	Negativa
Correto	Positiva	a	b	c
	Neutra	d	e	f
	Negativa	g	h	i

Tabela 4.2: Elementos para classificação métrica das mensagens (Benevenuto, Ribeiro, & Araújo, 2015)

Assim, utilizando a tabela 4.2 como referência, a métrica revocação (R) positiva é definida como (V),

$$R_+ = a / (a + b + c) \quad (\text{V})$$

a métrica precisão (P) positiva é definida como (VI)

$$P_+ = a / (a + d + g) \quad (\text{VI})$$

e a média harmônica entre P_+ e R_+ (F1) é definida como (VII)

$$F1_+ = 2 \times (P_+ \times R_+ / P_+ + R_+) \quad (\text{VII})$$

A métrica revocação (R) neutra é definida como (VIII),

$$R_0 = e / (d + e + f) \quad (\text{VIII})$$

a métrica precisão (P) neutra é definida como (IX)

$$P_0 = e / (b + e + h) \quad (\text{IX})$$

e a média harmônica entre P_0 e R_0 (F1) é definida como (9)

4. Metodologia.

$$F1_0 = 2 \times (P_0 \times R_0 / P_0 + R_0) \quad (X)$$

A métrica revocação (R) negativa é definida como (10)

$$R = i / (g + h + i) \quad (XI)$$

a métrica precisão (P) negativa é definida como (XII)

$$P = i / (c + f + i) \quad (XII)$$

e a média harmônica entre P- e R- (F1) é definida como (XIII)

$$F1 = 2 \times (P \times R / P + R) \quad (XIII)$$

5. Iterações.

5. Iterações.

Conforme citado na seção 4.1, foram efetuadas três iterações durante a pesquisa. Estas iterações permitiram efetuar avaliações, análises e aperfeiçoamentos do artefato desenvolvido. Abaixo são apresentados os resultados encontrados durante as iterações da pesquisa. Foram enumerados 990 posts, ou mensagens, no total, relativos a 39 *MOOCs* da Aulaberta. Destes 990 posts, 560 foram classificados manualmente (anotados) como fato, e 430 posts foram classificados manualmente como opinião, conforme ilustra a tabela 5.1.

	Número de <i>posts</i>
Opinião	430
Fato	560
Total	990

Tabela 5.1: Total de *posts* classificados manualmente (anotados) como fato ou opinião (autor).

Nota-se que foram classificados *posts* com conteúdo factual (56,57%) em maior quantidade do que *posts* com conteúdo opinativo (43,43%).

5.1. Primeira iteração.

A primeira iteração utiliza os passos metodológicos já definidos anteriormente em 4.2.4 para efetuar a classificação da polaridade de sentimento dos *posts*. O método de classificação proposto nesta primeira iteração se encontra definido abaixo.

5.1.1. O método proposto de análise combinada de sentimento na primeira iteração.

O método de análise de sentimento proposto na primeira iteração, baseado no trabalho de (Pinto & Rocio, 2019), consiste em obter uma combinação da análise de sentimento de quatro ferramentas (APIs) com o objetivo de aumentar a precisão da

5. Iterações.

predição final. Para o efeito, na primeira iteração a proposta foi obter a média aritmética dos scores individuais das quatro ferramentas (APIs) (I).

$$\text{Média Aritmética dos Scores} = (\sum \text{SCORES}) \div n \quad (\text{I})$$

5.1.2. Avaliação e resultado da análise de sentimento na primeira iteração.

O objetivo desta seção é demonstrar os resultados obtidos pela classificação da polaridade de sentimento das APIs em uma primeira iteração, individualmente, e o resultado obtido pela classificação da polaridade de sentimento a partir do *score* médio, ou polaridade média, como doravante será nomeado. A tabela 5.2 ilustra o quantitativo de *posts* opinativos classificados por polaridade, independentemente do percentual do *score*, para cada API, para a classificação manual e para a polaridade média.

	Número de <i>posts</i>		
	Negativos	Neutros	Positivos
Dados classificados manualmente	73	38	319
Amazon Comprehend	11	203	216
Google Natural Language	26	66	338
Microsoft Text Analytics	57	0	373
IBM Natural Language Understanding	21	21	388
Polaridade média	23	0	407

Tabela 5.2: Total de *posts* classificados por polaridade na primeira iteração (autor).

Do total de 430 *posts* opinativos contidos na base de dados, verifica-se que prevaleceu a quantidade de classificações de polaridade positiva em relação às classificações neutras e negativas. Em média, 79,11% das postagens foram classificadas como positivas, 12,71% foram classificadas como neutras e 8,18% foram classificadas como negativas. A API Amazon Comprehend classificou 47,20% das postagens como

5. Iterações.

neutras e a API Microsoft Text Analytics e o método da polaridade média não classificaram nenhum *post* com a polaridade neutra. A tabela 5.3 mostra os valores encontrados para as métricas *recall*, *precision* e *F1-Score*, já definidas na seção 4.3.

	R+	R0	R-	P+	P0	P-	F1+	F10	F1-
Polaridade média	0,99	0,00	0,30	0,78	0,00	0,95	0,87	0,00	0,45
IBM Natural Language	0,96	0,21	0,26	0,79	0,38	0,90	0,87	0,27	0,40
Microsoft Text Anal.	0,95	0,00	0,49	0,81	0,00	0,63	0,87	0,00	0,55
Google Nat. Language	0,88	0,31	0,24	0,83	0,18	0,69	0,85	0,23	0,36
Amazon Comprehend	0,61	0,92	0,13	0,91	0,17	0,90	0,73	0,29	0,23

Tabela 5.3: Métricas recall, precisão e F1-SCORE das APIs e do score médio na primeira iteração (autor).

No geral, os valores mais expressivos foram obtidos nas classificações positivas, que representam grande parte das postagens. Os valores das métricas mostradas na tabela 5.3 foram obtidos com todos os percentuais de *scores* gerados, portanto, a polaridade média também reflete a média de todos estes percentuais gerados pelas APIs. Outro ponto a ser destacado é que as métricas da polaridade média geraram o valor zero para as classificações de polaridade neutras. A explicação para este ponto reside no fato de que para ser considerada neutra a polaridade deve possuir *score* zero, e dificilmente uma média aritmética será zero, a menos que todos os quatro valores de *score* sejam zero.

5.2. Segunda iteração.

O objetivo da segunda iteração é verificar se é possível melhorar ou aumentar a precisão dos resultados obtidos na primeira iteração. Assim, nesta segunda iteração, é verificada e avaliada a polaridade dos *posts* cujo percentual de confiabilidade, ou *score*, é maior ou igual a 50%.

5. Iterações.

5.2.1. O método proposto de análise combinada de sentimento na segunda iteração.

Na segunda iteração, é efetuada uma simulação hipotética com os *scores* acima de 0.50, ou seja, somente são avaliados os scores com um percentual de confiança acima de 50%, inclusive. Esta simulação é denominada hipotética pois descarta os resultados com menos de 50% de confiabilidade, e esta situação não é desejada em um contexto real (II).

$$\text{Média Aritmética dos Scores} = (\sum \text{SCORES} > .50) \div n \quad \text{(II)}$$

5.2.2. Avaliação e resultado da análise de sentimento na segunda iteração.

Na segunda iteração, em uma situação hipotética, foram escolhidos os *scores* com percentuais acima de 0,50 (50%). Neste caso, ocorreu um aumento da confiabilidade dos resultados, mas por outro lado, o número de *posts* classificados com confiabilidade acima de 50% é menor, como mostra a tabela 5.4. Esta situação é hipotética, porque em um ambiente real não é possível simplesmente descartar os *scores* gerados com percentuais abaixo de 0,50, ou 50%.

	Número de <i>posts</i>		
	Negativos	Neutros	Positivos
Dados classificados manualmente	8	1	177
Amazon Comprehend	2	4	180
Google Natural Language	4	11	171
Microsoft Text Analytics	4	0	182
IBM Natural Language Understanding	3	1	182
Polaridade média	3	0	183

Tabela 5.4: Total de *posts* classificados por polaridade com score acima de 50% na segunda iteração (autor).

5. Iterações.

A tabela 5.5 mostra o aumento das métricas em todas as APIs e na polaridade média, de forma mais expressiva na métrica *precision*, que sobe de 0,78 com todos os *scores* positivos para 0,96 com todos os *scores* positivos com mais de 50% de confiabilidade. Com o aumento da confiabilidade das classificações, representado pelo aumento percentual dos *scores*, é possível verificar que a polaridade média torna-se uma boa opção para a classificação de polaridade de sentimentos, salvo no caso da análise da polaridade neutra.

	R+	R0	R-	P+	P0	P-	F1+	F10	F1-
Polaridade média	1,00	0,00	1,00	0,96	0,00	1,00	0,98	0,00	0,54
IBM Natural Language	0,99	0,00	1,00	0,96	0,00	1,00	0,98	0,00	1,00
Microsoft Text Anal.	0,99	0,00	1,00	0,96	0,00	1,00	0,98	0,00	1,00
Google Nat. Language	0,94	0,00	1,00	0,97	0,00	1,00	0,96	0,00	1,00
Amazon Comprehend	0,98	0,00	0,66	0,96	0,00	1,00	0,97	0,29	0,80

Tabela 5.5: Métricas recall, precisão e F1-SCORE das APIs e da polaridade média com *scores* acima de 50% na segunda iteração (autor).

5.3. Terceira iteração.

A terceira iteração é uma proposta de aperfeiçoamento do modelo de análise ou classificação combinada do sentimento. A partir dos resultados obtidos na primeira e segunda iterações, propõe-se um modelo de análise que pondera os *scores* obtidos pelas APIs de Análise de Sentimento. O modelo proposto é definido abaixo.

5.3.1. O método proposto de análise combinada de sentimento na terceira iteração

Na terceira iteração é proposto um método que efetua uma média ponderada pelos *scores*.
(III)

5. Iterações.

$$\text{Média Aritmética dos Scores} = \left(\sum \text{SCORES} \times \text{Peso} \right) \div \sum \text{Peso} \quad \text{(III)}$$

Onde Peso = Quantidade de ocorrências da polaridade.

Além do cálculo com os pesos, foi admitida uma faixa de valores do *score* médio ponderado para determinação da polaridade nula, variando no intervalo de **-0.08 a +0.08**. Este valor foi obtido empiricamente, a partir das iterações do artefato.

5.3.2. Avaliação e resultado da análise de sentimento na terceira iteração.

O objetivo da terceira iteração é promover um aperfeiçoamento do algoritmo responsável por efetuar a classificação da polaridade de sentimento a partir das médias das polaridades das APIs. Com a utilização de pesos, ou ponderamentos, o algoritmo irá “escolher”, ou privilegiar, as polaridades repetidas classificadas pelas APIs. A tabela 5.8 ilustra o funcionamento do algoritmo.

	Número de <i>posts</i>		
	Negativos	Neutros	Positivos
Dados classificados manualmente	73	38	319
Amazon Comprehend	11	203	216
Google Natural Language	26	66	338
Microsoft Text Analytics	57	0	373
IBM Natural Language Understanding	21	21	388
Polaridade média ponderada	22	13	395

Tabela 5.6: Total de *posts* classificados por polaridade com polaridade média ponderada na terceira iteração

(autor)

5. Iterações.

	R+	R0	R-	P+	P0	P-	F1+	F10	F1-
Polaridade média pond.	0,99	0,13	0,28	0,80	0,38	0,95	0,88	0,19	0,44
IBM Natural Language	0,96	0,21	0,26	0,79	0,38	0,90	0,87	0,27	0,40
Microsoft Text Anal.	0,95	0,00	0,49	0,81	0,00	0,63	0,87	0,00	0,55
Google Nat. Language	0,88	0,31	0,24	0,83	0,18	0,69	0,85	0,23	0,36
Amazon Comprehend	0,61	0,92	0,13	0,91	0,17	0,90	0,73	0,29	0,23

Tabela 5.7: Métricas recall, precisão e F1-SCORE das APIs e da polaridade média ponderada na terceira iteração (autor).

A tabela 5.7 ilustra as métricas geradas a partir da terceira iteração do algoritmo. De forma geral, houve um ganho em todas as métricas em relação à primeira iteração, exceto nas métricas *recall* e *f1-score* da polaridade negativa, provavelmente devido a uma leve mudança de polaridade negativa para neutra.

Seq.	Polaridades das APIs				Pesos				Score médio ponderado	Polaridade média
1	neu	pos	pos	pos	1	3	3	3	0.5326635939582826	pos
2	neu	pos	pos	pos	1	3	3	3	0.31346791077647224	pos
3	pos	pos	pos	pos	4	4	4	4	0.9254777588415145	pos
4	neu	pos	pos	neu	2	2	2	2	0.20715736447143554	pos
5	neu	neg	neu	pos	2	1	2	1	0.06727195779482524	neu
6	pos	neg	pos	pos	3	1	3	3	0.7273879059360504	pos
7	neu	neg	neu	pos	2	1	2	1	0.04388094941775005	neu
8	neu	pos	pos	pos	1	3	3	3	0.6697323464515685	pos
9	neg	pos	neg	pos	2	2	2	2	-0.03754008374249927	neu
10	pos	pos	pos	pos	4	4	4	4	0.600689202850342	pos
11	neu	neg	pos	pos	1	1	2	2	0.35070449726772296	pos
12	neu	pos	neu	neg	2	1	2	1	0.011884617308775672	neu
13	neu	pos	pos	pos	1	3	3	3	0.38778877054252625	pos
14	neu	neg	neg	neg	1	3	3	3	-0.3135711678603171	neg
15	neu	pos	pos	pos	1	3	3	3	0.2519927301505565	pos
16	neu	neg	neu	neu	3	1	3	3	-0.0664607465267181	neu
17	neu	pos	pos	neu	2	2	2	2	0.23048725050354002	pos
18	neu	pos	neg	neg	1	1	2	2	-0.2695583680731453	neg
19	pos	pos	pos	pos	4	4	4	4	0.48544955525350575	pos
20	pos	pos	pos	pos	4	4	4	4	0.6130038547178505	pos

Tabela 5.8: Exemplo de classificação efetuada pelo algoritmo de ponderação criado na terceira iteração (autor).

5. Iterações.

A fim de exemplificar o cálculo (III) efetuado pelo algoritmo durante a terceira iteração, é mostrada a tabela 5.8, com a polaridade primária gerada pelas quatro APIs, os pesos de cada classificação primária, o *score* médio calculado e a sua polaridade. Como citado anteriormente, o algoritmo efetua uma escolha, ou “voto”, na escolha mais comum das classificações primárias. Por exemplo, na sequência 1, as APIs efetuaram as classificações das polaridades primárias como: neutra, positiva, positiva, positiva. O peso atribuído a cada classificação foi 1,3,3,3 e a polaridade resultante da classificação de polaridade ponderada foi positiva. Um exemplo interessante encontra-se na sequência 9: as classificações das polaridades primárias foram: negativa, positiva, negativa, positiva. A polaridade resultante da classificação ponderada foi neutra. O fato é explicado pelo *score* ponderado resultante, cujo valor foi: -0.037. Neste caso, como o intervalo está entre os limites de -0.08 e +0.08 definido no algoritmo como uma possível neutralidade, a polaridade foi classificada como neutra. De fato, na sequência 9, observa-se um impasse: duas classificações de polaridade positiva e duas classificações de polaridade negativa. O algoritmo define o mesmo peso para as classificações e efetua o cálculo do *score* ponderado, indicando uma polaridade neutra.

5.4. Análise das iterações.

As três iterações foram necessárias para efetuar análises e ajustes no algoritmo que calculou a média aritmética ponderada dos sentimentos. A primeira iteração foi efetuada somente com a classificação média dos *scores*. Já durante a primeira iteração, a partir dos resultados gerados durante a avaliação das métricas (tabela 5.3), verificou-se um aumento da precisão da classificação pela média aritmética em relação às classificações das APIs separadamente. Na segunda iteração o objetivo foi efetuar uma simulação para verificar se o aumento dos *scores*, e consequentemente, o aumento da confiabilidade das classificações, representaria um aumento das métricas de verificação da precisão das classificações. Esta simulação hipotética testou somente os *scores* com classificação acima de 0.50, ou seja, 50%. Os resultados da segunda iteração indicaram que, com o aumento dos *scores*, a média ponderada também aumenta. A segunda iteração foi importante para verificar a necessidade

5. Iterações.

de criar um mecanismo de melhoria e balanceamento dos *scores* gerados pelas APIs. A terceira iteração efetuou a ponderação dos *scores*, criando um peso maior para polaridades repetidas. Desta forma, as polaridades que se repetissem dentro das quatro classificações teriam um peso relativo ao seu número de repetições, criando assim a possibilidade de “escolha” das polaridades repetidas e aumento da confiabilidade da classificação.

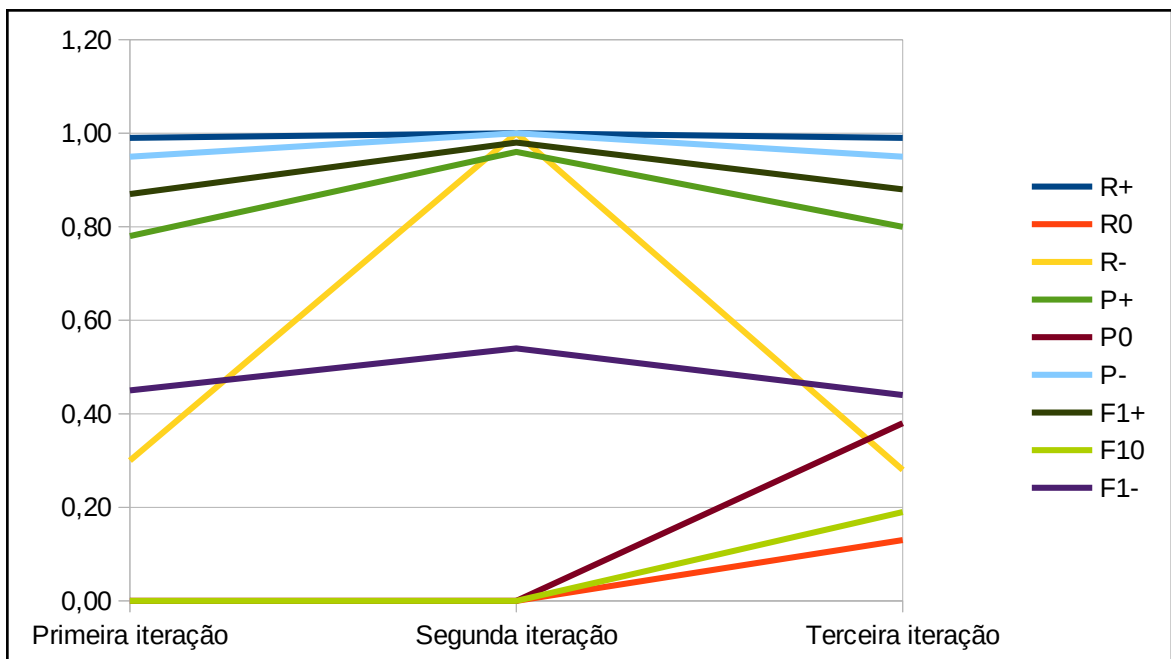


Gráfico 5.1: Relação entre as métricas e as iterações (autor)

O gráfico 5.1 mostra os resultados da avaliação das métricas *recall*, *precision* e *f1-score* da métrica ponderada durante as três iterações do desenvolvimento da pesquisa. Pode-se concluir, analisando o gráfico 5.1 e a tabela 5.3, que na primeira iteração já ocorreu um ganho de precisão nas métricas em relação à classificação das APIs. O problema que ocorre nesta iteração é o fato de o algoritmo não ter efetuado classificações neutras (R0,P0,F10). Como não é utilizado nenhum peso ou faixa de valor, somente o *score* 0.00 (zero) gera uma classificação de polaridade neutra, fato que compromete o algoritmo como um todo. As medições restantes geram valores bastante satisfatórios

5. Iterações.

(tabela 5.3). A segunda iteração efetua uma simulação de valores, a partir de classificações com maior confiabilidade, mas ainda assim, simuladas, pois os valores com confiabilidade menor foram descartados, não possuindo este descarte um valor prático. O gráfico 5.1 e a tabela 5.4 demonstram a segunda iteração e os valores simulados. Como na segunda iteração os valores dos scores são fixados em 50%, ocorre um aumento expressivo da precisão de todas as classificações, gerando um ápice de valores no gráfico 5.1. Nota-se também na primeira e segunda iterações que as classificações da polaridade neutra são praticamente inexistentes, isto devido à falta de definição de um intervalo de valores limítrofes para a classificação da polaridade neutra. Na terceira e última iteração é proposto o método combinado da polaridade média aritmética ponderada (Pinto & Rocio, 2019). Este método cria pesos, ou seja, efetua uma ponderação entre as classificações com a mesma polaridade, permitindo ao algoritmo “escolher” ou “votar” as polaridades repetidas. A tabela 5.8 ilustra os resultados das classificações e ponderações do algoritmo.

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.

O objetivo secundário deste trabalho é utilizar o *score* médio ponderado para verificar se existe relação entre a polaridade de sentimento expresso nos *posts* dos estudantes e o seu aproveitamento acadêmico nos *MOOCs* da Universidade Aberta de Portugal. Para isso, é necessário efetuar a classificação da polaridade dos sentimentos expressos em textos escritos nestes *posts* e confrontar este resultado com indicadores do aproveitamento do estudante, para então efetuar alguma análise quantitativa.

A classificação da polaridade ocorre no nível do estudante e no nível do curso *MOOC*, ou seja, foram classificadas as polaridades de sentimento por estudante e por curso *MOOC* e estudante. As únicas informações disponíveis para analisar a performance (rendimento) do aluno são as notas e os indicativos de conclusão de atividades e módulos. De um total de onze mil e setenta e cinco (11075) estudantes cadastrados no ambiente *MOOC* da Aula Aberta, onze mil e quarenta e oito (11048) estão ativos e vinte e sete (27) estão inativos. Do total de estudantes ativos na plataforma, duzentos e sessenta e sete (277) efetuaram *posts* e deste total, cento e vinte e cinco (125) foram considerados opinião. Portanto, foram geradas cento e vinte e cinco análises (125) de polaridade de sentimento nos textos que representam os *posts* dos estudantes.

Dos estudantes ativos na plataforma, trezentos e quarenta e quatro (344) possuem nota e sessenta e seis (66) não possuem notas lançadas. A primeira etapa de verificação compara a polaridade do sentimento geral do estudante com as suas notas. A polaridade do sentimento geral do estudante foi obtida a partir da sumarização das polaridades de sentimento de todos os seus *posts*, como mostrado no item 4.2.3.6. As notas foram obtidas a partir da normalização das notas retiradas e coletadas diretamente da base de dados dos *MOOCs*. Para esta primeira etapa foram encontrados sessenta e nove (69) registros, que são resumidos nas tabelas e figuras abaixo. A tabela 6.1 ilustra a quantidade de *posts* analisados e a nota média, máxima e mínima dos estudantes. A baixa quantidade de *posts* (69) em relação ao total citado anteriormente (430) se deve ao fato de ter sido efetuada uma intersecção entre os estudantes que efetuaram *posts* e foram classificados como

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.

opinião e os estudantes que possuem nota no ambiente *MOOC*. Observa-se que a relação entre as notas e os *posts* não é bem definida, ocorrendo uma leve queda de valores entre polaridade positiva e negativa para a nota média e nenhuma relação com a nota mínima e máxima.

	<i>Posts</i>		
	Positivos	Neutros	Negativos
Quantidade	59	2	8
Nota média (%)	80,62	83,13	78,57
Nota mínima (%)	0,00	0,00	64,02
Nota máxima (%)	100,00	83,13	100,00

Tabela 6.1: Quantidade de *posts*, nota média, máxima e mínima por polaridade (autor).

Em relação às notas individuais, também não foi encontrada uma relação direta entre a polaridade positiva e negativa. A série de notas se comportou da mesma forma, não sendo possível observar notas maiores para estudantes com a polaridade de sentimento geral positiva (gráfico 6.1) ou notas menores para estudantes com polaridade de sentimento geral negativa (gráfico 6.2). A polaridade neutra não foi avaliada por possuir somente dois (2) registros.

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.



Gráfico 6.1: Estudantes e notas por polaridade positiva de sentimento (autor).




Gráfico 6.2: Estudantes e notas por polaridade negativa de sentimento (autor).

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.

A segunda etapa de verificação compara a polaridade de sentimento geral do estudante com o seu percentual total de conclusão do curso. O percentual de conclusão do curso foi obtido a partir de normalizações dos percentuais de conclusão de atividades e módulos extraídos, coletados e transformados diretamente da base de dados dos *MOOCs*.

Na segunda etapa foram encontrados cento e três (103) registros, que são resumidos nas tabelas e figuras abaixo. A tabela 6.2 ilustra a quantidade de *posts* analisados e os percentuais de conclusão médio, mínimo e máximo dos estudantes. Novamente, a quantidade de *posts* difere da total porque não são todos os cursos e estudantes que possuem registro da conclusão das atividades. Novamente não é encontrada uma relação entre os percentuais de conclusão das atividades e as polaridades de sentimento positivas, neutras e negativas. Observa-se inclusive que os percentuais de conclusão para as polaridades negativas possuem valores mais altos do que os percentuais de conclusão para as polaridades positivas, como mostrados na tabela 6.2. É importante observar também que a pequena quantidade de *posts* negativos enfraquece a análise.

	<i>Posts</i>		
	Positivos	Neutros	Negativos
Quantidade	94	2	7
Conclusão média (%)	98,94	100,00	100,00
Conclusão mínima (%)	66,67	100,00	100,00
Conclusão máxima (%)	100,00	100,00	100,00

Tabela 6.2: Quantidade de *posts* por estudante e percentual de conclusão médio, máximo e mínimo por polaridade (autor).

O gráfico 6.3 mostra os percentuais individuais de conclusão de curso, indicando que também não existe relação entre os percentuais de conclusão e as polaridades positivas, ou seja, um estudante com polaridade de sentimento positiva expressa pelos seus *posts* não necessariamente possui altos índices de conclusão de curso.

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.




Gráfico 6.3: Estudantes e percentual de conclusão por polaridade positiva de sentimento (autor).

De forma análoga, na análise para a polaridade negativa de sentimento não foram observados percentuais baixos de conclusão de atividades e módulos de cursos entre os estudantes que expressaram polaridade negativa em suas postagens. Ao contrário, todos os estudantes cuja análise de sentimento indicou a polaridade negativa como predominante tiveram cem (100) por cento de percentual de término de curso. A terceira etapa de verificação comparou a polaridade de sentimento do estudante em determinado curso e sua nota neste mesmo curso. A polaridade do sentimento do estudante foi obtida a partir das postagens por curso. Para a comparação entre o sentimento do estudante por curso e sua nota foi selecionado o curso com maior representatividade de postagens e notas de estudantes, denominado: Migrações Forçadas e Refugiados.

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.

MOOC Migrações Forçadas e Refugiados (22)	Posts		
	Positivos	Neutros	Negativos
Quantidade	10	0	6
Nota média (%)	68,02	0,00	82,47
Nota mínima (%)	0,00	0,00	64,76
Nota máxima (%)	96,67	0,00	100,00

Tabela 6.3: Quantidade de *posts* por estudante, MOOC Migrações forçadas e refugiados e respectiva nota média, máxima e mínima por polaridade (autor).

As notas média, mínima e máxima mostraram (tabela 6.3) novamente que não existem relações diretas e inequívocas entre a polaridade de sentimento do estudante e sua nota.

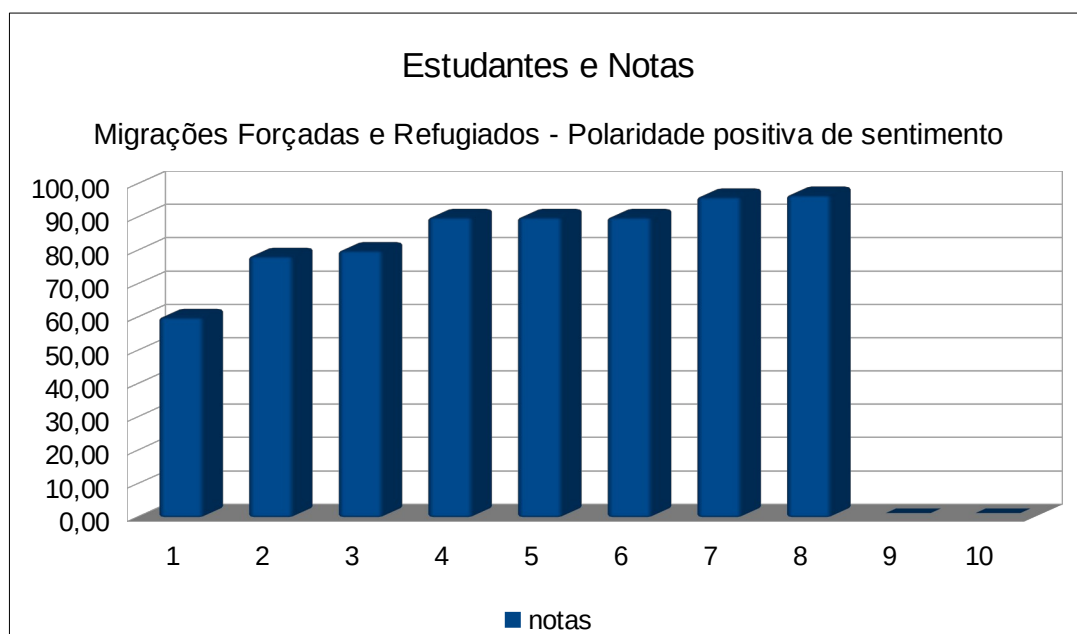


Gráfico 6.4: Estudantes e notas do MOOC Migrações Forçadas e Refugiados por polaridade positiva de sentimento (autor).

Os gráficos 6.4 e 6.5 mostram notas com grandezas variáveis, também sem relação direta entre a polaridade de sentimento e as notas, indicando que não há evidência de relação entre a polaridade do sentimento e a nota do estudante.

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.




Gráfico 6.5: Estudantes e notas do *MOOC Migrações Forçadas e Refugiados* por polaridade negativa de sentimento (autor).

Finalmente, a quarta etapa de verificação efetuou uma comparação entre a polaridade de sentimento do estudante em determinado curso e o seu percentual de conclusão neste curso. Para esta última etapa de verificação foi selecionado o curso: A Biblioteca Escolar e o Desenvolvimento das Literacias. Não foram classificados *posts* negativos para este curso, de forma que a análise tornou-se prejudicada por possuírem apenas postagens classificadas com polaridade positiva, conforme mostram a tabela 6.4 e o gráfico 6.6.

MOOC A Biblioteca Escolar e o Desenvolvimento das Literacias (23)	<i>Posts</i>		
	Positivos	Neutros	Negativos
Quantidade	60	1	0
Conclusão média (%)	99,56	100,00	0,00
Conclusão mínima (%)	85,71	100,00	0,00
Conclusão máxima (%)	100,00	100,00	0,00

Tabela 6.4: Quantidade de *posts* por estudante, *MOOC A Biblioteca Escolar e o Desenvolvimento das Literacias* e respectivo percentual de conclusão médio, máximo e mínimo por polaridade (autor).

6. Resultados da relação entre a análise do sentimento e o aproveitamento do estudante.

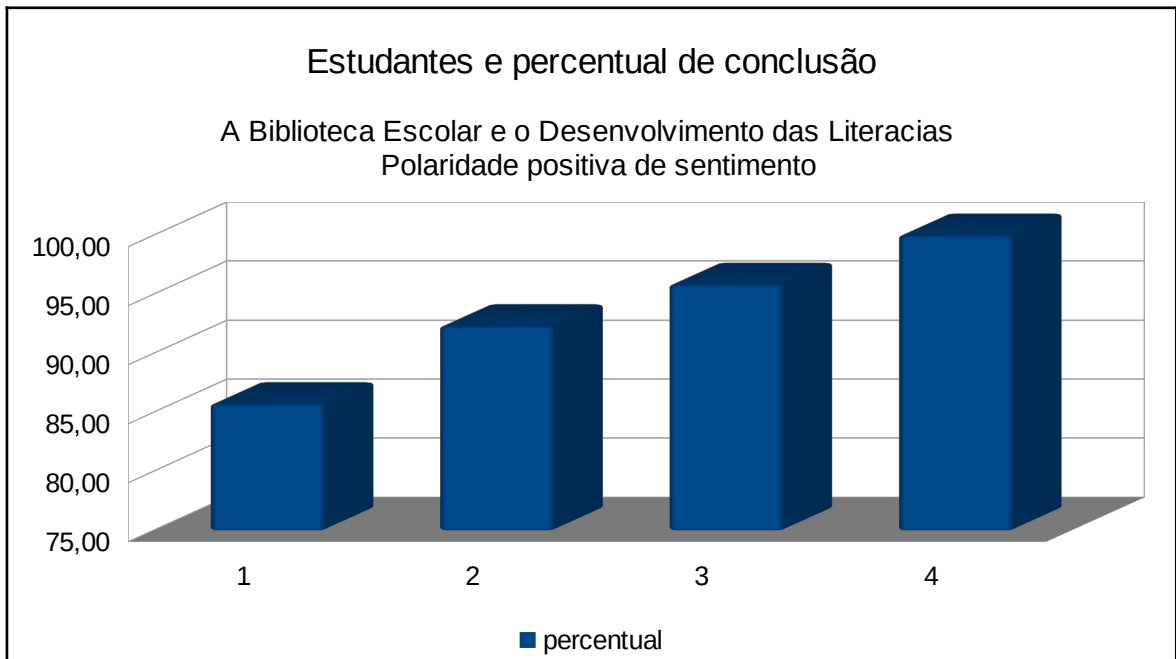


Gráfico 6.6: Estudantes e percentual de conclusão do *MOOC* A Biblioteca Escolar e o Desenvolvimento das Literacias por polaridade positiva de sentimento (autor).

De forma geral, os dados indicaram que não existe evidência de relação direta entre a polaridade de sentimento expressa pelos estudantes e o seu rendimento (performance) acadêmico nos cursos *MOOC* da Universidade Aberta de Portugal.

7. Conclusões.

7. Conclusões.

O objetivo principal desta pesquisa foi processar coleções de documentos representadas pelas interações nos fóruns educacionais em *MOOC* da Universidade Aberta de Portugal para obter registros textuais dos estudantes e demonstrar um método eficaz para a classificação da polaridade dos sentimentos extraídos destes registros textuais dos estudantes. O ensino à distância possui particularidades que comprometem a interação humana, tornando imperativos os estudos e pesquisas que diminuam esse comprometimento, buscando assim atividades de ensino mais efetivas e impedindo a interrupção dos estudos por parte do público-alvo: o estudante. Baseado nos trabalhos relacionados e na presente pesquisa pode-se chegar a algumas lições aprendidas e conclusões.

O trabalho introdutório de Pinto & Rocio (2019) mostra que é possível um ganho de precisão nas análises de sentimento efetuadas nos ambientes *MOOC*, com a utilização da média aritmética das classificações das polaridades efetuadas a partir de quatro APIs utilizadas como exemplo para este fim. É importante salientar que as APIs utilizadas como exemplo foram escolhidas a partir de informações contidas no trabalho de Dale (2018).

No que diz respeito às questões de pesquisas relacionadas com a adequação, vantagens e eficiência na utilização de ferramentas fornecidas por *players* do mercado, pode-se concluir que todas as APIs foram adequadas e forneceram resultados satisfatórios para os *posts* dos estudantes em *MOOC* da Universidade Aberta de Portugal, oferecendo uma vantagem competitiva em relação ao desenvolvimento de métodos próprios de análise de sentimento, por questões de praticidade, velocidade e confiabilidade. Quanto à questão de pesquisa referente à escolha ou combinação de ferramentas mais indicadas em termos de precisão para a utilização em ambiente *MOOC*, foi definido um método que combina as quatro classificações das APIs. O método permite “escolher” a classificação mais precisa dentre um conjunto de quatro classificações, criando um *score* médio ponderado a partir de quatro *scores*. As classificações com mesma polaridade ganham um peso maior em relação às outras classificações, já que polaridades iguais representam um aumento do percentual

7. Conclusões.

de confiabilidade da classificação. Assim, de acordo com os resultados das três iterações, apesar deste ser um trabalho introdutório, chegou-se à conclusão que o método proposto por Pinto & Rocio (2019) é válido para o aumento da precisão das classificações das postagens dos estudantes em *MOOCs* da Universidade Aberta de Portugal.

Quanto à questão de pesquisa relacionada com o abandono e o rendimento do estudante e sua expressão sentimental, esta pesquisa não verificou relação direta entre a polaridade dos sentimentos dos estudantes e o rendimento acadêmico destes, fato corroborado também por Koutropoulos et al.(2012) e Wen, Yang, & Rosé (2014). Por hipótese, esperava-se que a incidência de polaridade positiva nas postagens de determinados estudantes indicassem seu bom rendimento nos cursos, e, de forma análoga, a incidência de polaridade negativa nas postagens indicasse um rendimento insuficiente, ou mesmo, abandono dos cursos *MOOC* da Universidade Aberta de Portugal, fato que não foi verificado nos dados coletados, processados e analisados. No entanto, esta pesquisa corrobora a importância da análise de sentimento como ferramenta de melhoria da gestão e da relação entre os estudantes e professores no contexto do ensino à distância. Como constatado anteriormente por (David et al., 2014), é importante compreender a expressão da afetividade no contexto do aprendizado e cognição humanos, e qual o impacto desta afetividade especificamente em contextos do ensino à distância, mas de forma controlada e em ambiente e cenários específicos, como cita Robinson, Yeomans, Reich, Hulleman, & Gehlbach (2016).

8. Trabalhos futuros e considerações.

8. Trabalhos futuros e considerações.

A pesquisa foi confrontada por algumas limitações, que acabaram por gerar oportunidades valiosas de melhoria. Tanto as limitações quanto as oportunidades de melhoria sugerem a possibilidade de trabalhos futuros e algumas considerações. Quanto à metodologia definida para a análise combinada dos sentimentos, denominada como *score* médio ponderado, as possibilidades são variadas. Inicialmente, a quantidade de APIs escolhidas para o propósito de combinação dos scores foi em número de quatro, mas existem outras possibilidades, como um número maior de APIs, e a quantidade ímpar de APIs, para se evitar impasses. A pesquisa utilizou a média aritmética simples ponderada para a combinação dos scores, mas existem outras médias, como a geométrica, ou mesmo a harmônica. Uma premissa utilizada durante a pesquisa definiu as APIs como uma caixa-preta, ou seja, não era importante entender o seu funcionamento interno. Utilizar o método do *score* médio ponderado em conjunto com abordagens variadas de análise de sentimento, levando em conta os processos internos de análise de sentimento, como em um comitê, deve ser considerada uma possibilidade de pesquisa futura. Outra possibilidade de pesquisa futura está ligada ao cálculo e verificação do *score* neutro no contexto do *score* médio ponderado: a faixa de valores obtidos para determinação do *score* e da polaridade neutros (-0.08 e +0.08) foi definida empiricamente, a partir das iterações no desenvolvimento da pesquisa. Uma possibilidade de pesquisa situa-se na criação de alternativas para o cálculo da polaridade neutra dentro do contexto do *score* médio ponderado. Finalizando, uma outra possibilidade de pesquisa é explorar a oportunidade de “marketing” a partir da verificação do sentimento dos alunos a determinados cursos MOOC, ou seja, pesquisar a aplicação de técnicas e ferramentas de propaganda aliadas ao sentimento positivo dado pelos estudantes a determinados cursos MOOC da Universidade Aberta de Portugal.

Foi criado, a partir dos trabalhos relacionados, das lições aprendidas e da experiência adquirida, um conjunto de recomendações para o processo de análise de sentimento em ambientes de ensino à distância, especificamente, *MOOC*, com o objetivo

8. Trabalhos futuros e considerações.

de nortear pesquisas futuras que venham a utilizar esta mesma temática e contribuir para o seu sucesso. Neste sentido foram definidas três considerações: **considerações sobre as características gerais e específicas do ambiente MOOC**; **considerações sobre os dados de pesquisa** e **considerações sobre a análise de sentimento no ambiente acadêmico MOOC**. Em relação às características gerais e específicas do ambiente MOOC, a primeira constatação importante é a necessidade de se conhecer mais especificamente as particularidades e diferenças do ambiente de ensino MOOC em relação aos ambientes tradicionais de ensino à distância. As características gerais do ambiente MOOC, já citadas anteriormente por Adamopoulos (2013), como flexibilidade em relação à participação de estudantes de variadas origens, grande distribuição territorial, devido à utilização de redes de universidades ao redor do mundo, ampla gama de domínios e assuntos e massificação do acesso pode influenciar no processo de análise do sentimento dos estudantes e de sua relação com a aprendizagem.

O trabalho de Koutropoulos et al.(2012), por exemplo, cita que as investigações devem levar em conta a característica de seus estudantes, efetuando uma separação dos estudantes ocasionais e desinteressados dos que realmente apresentam interesse e compromisso com a aprendizagem. Quanto às características específicas, é importante avaliar pontualmente o curso MOOC oferecido em busca de configurações específicas: alguns cursos efetuam a avaliação dos estudantes por meio de notas, outros cursos efetuam a avaliação dos estudantes por meio de conclusão e acompanhamento de tarefas e atividades.

A existência ou falta de atividades específicas como questionários, fóruns, *chats* ou mesmo *wikis* podem influenciar todo o processo de análise do sentimento. Assim, concordando com Wen, Yang, & Rosé (2014), deve haver uma relação mais próxima de contexto e entendimento entre determinado curso MOOC e a análise de sentimento de seus estudantes. De forma resumida, deve-se verificar melhor as características de cada curso MOOC e suas particularidades, como o contrato do curso, suas avaliações e suas atividades, bem como os estudantes matriculados e suas características. Talvez seja necessário repensar a sistemática de avaliação dos MOOCs. Vários autores citam uma limitação quantitativa (Wen, Yang, & Rosé, 2014; Bergner, Kerr, & Pritchard, 2015;

8. Trabalhos futuros e considerações.

Robinson, Yeomans, Reich, Hulleman, & Gehlbach, 2016) quanto aos dados disponibilizados no ambiente *MOOC* para uso em pesquisas.

Essa limitação foi verificada na presente pesquisa: dos cerca de 30 cursos cadastrados na plataforma AulAberta, somente 4 possuíam número relevante de postagens dos estudantes, a despeito da quantidade de estudantes cadastrados no ambiente *MOOC* (11075 estudantes). Conforme mostra o ítem 6, algumas análises foram comprometidas. Cabe verificar se existe relação entre a baixa disponibilidade de dados para pesquisa e as características intrínsecas a todos os cursos *MOOC*, ou trata-se apenas de uma particularidade. Outra questão que deve ser considerada em relação aos dados disponíveis para a pesquisa é a qualidade dos mesmos: alguns autores (Wen, Yang, & Rosé, 2014; Bergner, Kerr, & Pritchard, 2015) citam a baixa qualidade dos dados utilizados nas investigações e outros autores (Moreno-Marcos, Alario-Hoyos, Munoz-Merino, Estevez-Ayres, & Kloos, 2018; Fei & Li, 2018) citam a complexidade e subjetividade do processo. Tanto a falta de qualidade quanto a complexidade e subjetividade dos dados interfere substancialmente no processo de análise de sentimento.

Outro ponto importante a ser considerado sobre os dados contidos no ambiente *MOOC* diz respeito à diferenciação entre fato e opinião. Como já teorizado por (Liu, 2012), é importante diferenciar textos objetivos e subjetivos: os textos objetivos exprimem fatos e os textos subjetivos exprimem opiniões. No contexto de um ambiente acadêmico de ensino à distância, é razoável inferir que os textos dos *posts* dos estudantes expressem fatos em maior quantidade do que opiniões, a não ser que estas sejam solicitadas. Outra consideração importante é a relação entre *posts* anotados com polaridade positiva (319) e negativa (74) encontradas na pesquisa, conforme mostra a tabela 4. Esta desproporção pode ser explicada devido ao constrangimento de se expressar uma opinião negativa fora do contexto e do espaço apropriado, levando a resultados imprecisos.

Então, considerando a necessidade da análise de sentimento no ambiente acadêmico e partindo do pressuposto que *posts* no ambiente *MOOC* são dedicados à aprendizagem do estudante e devem conter fatos e opiniões somente sobre o conteúdo ministrado, devemos inferir que as opiniões pessoais sobre determinado assunto relativo à gestão e funcionamento dos cursos deve ser obtida em um espaço separado e controlado.

8. Trabalhos futuros e considerações.

Assim, a partir da necessidade de obter informações significativas sobre os sentimentos dos estudantes no ambiente *MOOC* e sua relação com a aprendizagem, torna-se importante uma sistematização dessa coleta dentro do próprio ambiente, configurando uma soma de métodos, processos, atividades e softwares utilizados unicamente para este fim. Partindo destas considerações, dos trabalhos relacionados e da presente pesquisa, pode-se definir um conjunto de recomendações que poderá auxiliar os investigadores durante a análise de sentimento em ambientes do ensino à distância, em especial, *MOOC*:

- **Entender as características e particularidades do ambiente *MOOC* a ser investigado:** Conforme constatado, é importante verificar e entender as características específicas e particularidades do ambiente *MOOC* que será investigado, pois esta verificação prévia permite ao investigador obter informações valiosas para adequação da pesquisa. Por exemplo, é importante verificar a quantidade de estudantes matriculados no curso; quais ferramentas de aprendizagem, como fórum, *chat*, *wiki*, etc, estão disponíveis para os estudantes; entender as formas de avaliação do curso; como é efetuada a interação entre os professores / tutores e estudantes, etc.
- **Criar mecanismos sistemáticos para a obtenção da opinião do estudante:** Conforme observado por esta pesquisa, extrair a opinião dos estudantes a partir de textos localizados em fóruns e outros meios disponibilizados para a aprendizagem pode comprometer os resultados, pois, mesmo que a análise de sentimento seja efetuada de forma espontânea, grande parte dos estudantes não considera o espaço virtual de interação e aprendizagem, como o fórum, um lugar ideal para a expressão de sentimento, por diversos fatores que extrapolam os domínios tecnológicos, e que também não são objeto da presente pesquisa. O trabalho de Robinson, Yeomans, Reich, Hulleman, & Gehlbach, (2016) mostra que pesquisas direcionadas e motivadas psicologicamente podem abrir um mundo de perspectivas para a análise de sentimento. Neste contexto, criar um mecanismo específico para coletar a opinião, como, por exemplo, um questionário com perguntas abertas e direcionadas

8. Trabalhos futuros e considerações.

ao final de cada módulo de aprendizagem ou indicadores e métricas de satisfação controlados pelo próprio estudante podem ser efetivos, em conjunto com técnicas de processamento de linguagem natural, para a análise de sentimento. Outra perspectiva de trabalho é utilizar um mecanismo para a coleta de opinião e sentimento do estudante e validar ou contrapor esta opinião com outras análises de sentimento em ambiente externo, como redes sociais periféricas e afins.

- **Coletar os dados de várias fontes:** Um problema encontrado em vários trabalhos relacionados (Wen, Yang, & Rosé, 2014; Bergner, Kerr, & Pritchard, 2015; Robinson, Yeomans, Reich, Hulleman, & Gehlbach, 2016) e também nesta pesquisa foi a limitada quantidade de dados para trabalho. Neste aspecto, é desejável obter o máximo de dados possível utilizando outras fontes, além das interações dos estudantes em fóruns, por exemplo. Uma boa fonte de dados pode ser o registro de atividades do usuário (*log*) na plataforma de ensino à distância, ou mesmo, os comentários dos estudantes em plataformas de redes sociais com temas relacionados ao curso. Como citado anteriormente, em ambientes externos ao ensino, como redes sociais, o estudante pode expressar seus sentimentos e emoções de forma espontânea.
- **Tratar os dados de forma consistente :** Este é um dos maiores desafios para análise de sentimento, pois está relacionado diretamente com o processamento e a qualidade dos dados que serão utilizados na análise. Devido a características gerais e particulares dos cursos MOOC, da complexidade e subjetividade existente no processo de análise de sentimento, a obtenção e tratamento dos dados também pode ser uma tarefa complexa. Conforme constata Wen, Yang, & Rosé (2014), o ruído existente naturalmente nos textos escritos em linguagem natural pode invalidar uma pesquisa, se não forem tomados os devidos cuidados. Portanto, atividades relativas à melhoria da qualidade dos dados, como a limpeza, manipulação de valores incorretos, escala e normalização (Aggarwal, 2015) efetuadas nos processos de

8. Trabalhos futuros e considerações.

extração, coleta, processamento até a sumarização podem influenciar diretamente na melhoria da qualidade do processo de análise de sentimento.

- **Definir a melhor ferramenta para efetuar classificação do sentimento:** Atualmente existem diversas técnicas (citadas na seção 2) e ferramentas criadas para a análise de sentimento e escolher as mais apropriadas para determinado contexto também é fator importante para o sucesso da análise e da pesquisa. Ao se utilizar abordagens léxicas, o uso de dicionários específicos para o contexto da pesquisa tende a gerar melhores resultados. Da mesma forma, ao se utilizar a abordagem de aprendizado de máquina, deve-se verificar se os dados de treinamento também fazem parte do contexto dos dados a serem classificados. Também existe a opção de utilizar ferramentas de terceiros, como utilizadas nesta pesquisa, ou efetuar a classificação com a utilização das várias ferramentas disponíveis. Estas escolhas dependem dos objetivos a serem alcançados pela pesquisa.

Finalizando, espera-se que as informações aqui apresentadas sejam úteis para a melhoria dos trabalhos relacionados ao tema, aumentando a qualidade das pesquisas e contribuindo para o avanço científico na área.

9. Referências.

9. Referências.

Adamopoulos, P. (2013). What makes a great MOOC ? An interdisciplinary analysis of student retention in online courses. *31th International Conference on Information Systems, 2013*, 21.

Aggarwal, C. C. (2015). *Data mining: The textbook*. Cham Heidelberg New York Dordrecht London: Springer.

Amazon Comprehend—Developer Guide. (2019). 351.

Araújo, M., Gonçalves, P., & Benevenuto, F. (2013). Métodos para Análise de Sentimentos no Twitter. *Brazilian Symposium on Multimedia and the Web (Webmedia)*, 8.

Becker, K. (2014). Introdução à Mineração de Opiniões. *Jornadas de Atualização em Informática - Congresso da SBC*, p. 51.

Benevenuto, F., Ribeiro, F., & Araújo, M. (2015). *Métodos para Análise de Sentimentos em mídias sociais*. 30. Manaus, Brazil.

Bergner, Y., Kerr, D., & Pritchard, D. E. (2015). *Methodological Challenges in the Analysis of MOOC Data for Exploring the Relationship between Discussion Forum Views and Learning Outcomes*. 9.

Chaplot, D. S., Rhim, E., & Kim, J. (2015). *Predicting Student Attrition in MOOCs using Sentiment Analysis and Neural Networks*. 7.

Chowdary, S. J. S., Farooq, S. W., Siddique, S. A., & Dinesh, S. (2019). Sentiment Analysis of movie reviews using Microsoft Text Analytics and Google Cloud Natural

9. Referências.

Language API. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, p. 4.

Dale, R. (2018). Text analytics APIs, Part 1: The bigger players. *Natural Language Engineering*, 24(2), 317–324. <https://doi.org/10.1017/S1351324918000013>

Dionísio, M., Cavalcanti, A., Ferreira, R., Miranda, P., Neto, S., & Oliveira, A. (2017, outubro 27). *Mineração de Textos em Fóruns Educacionais: Uma revisão da literatura*. 21. <https://doi.org/10.5753/cbie.sbie.2017.21>

Fei, H., & Li, H. (2018). The Study of Learners' Emotional Analysis Based on MOOC. In J. Xiao, Z.-H. Mao, T. Suzumura, & L.-J. Zhang (Orgs.), *Cognitive Computing – ICC3 2018* (Vol. 10971, p. 170–178). https://doi.org/10.1007/978-3-319-94307-7_14

Feldman, R., & Sanger, J. (2007). *The text mining handbook: Advanced approaches in analyzing unstructured data*. Recuperado de <http://www.books24x7.com/marc.asp?bookid=23164>

Feng, Y., Chen, D., Zhao, Z., Chen, H., & Xi, P. (2015). The Impact of Students And TAs' Participation on Students' Academic Performance in MOOC. *Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining 2015 - ASONAM '15*, 1149–1154. <https://doi.org/10.1145/2808797.2809428>

Ferguson, R. (2012). Learning analytics: Drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 4(5/6), 304. <https://doi.org/10.1504/IJTEL.2012.051816>

Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64–71. <https://doi.org/10.1007/s11528-014-0822-x>

9. Referências.

- Herselman, M., & Botha, A. (2015). Evaluating an Artifact in Design Science Research. *Proceedings of the 2015 Annual Research Conference on South African Institute of Computer Scientists and Information Technologists - SAICSIT '15*, 1–10. <https://doi.org/10.1145/2815782.2815806>
- Hughes, G., & Dobbins, C. (2015). The utilization of data analysis techniques in predicting student performance in massive open online courses (MOOCs). *Research and Practice in Technology Enhanced Learning*, 10(1), 10. <https://doi.org/10.1186/s41039-015-0007-z>
- KNIME Quickstart Guide*. (2018). 26. (https://docs.knime.com/2018-12/analytics_platform_quickstart_guide/analytics_platform_quickstart_guide.pdf).
- Koutropoulos, A., Gallagher, M. S., Abajian, S. C., Waard, I. de, Hogue, R. J., Keskin, N. Ö., & Rodriguez, C. O. (2012). Emotive Vocabulary in MOOCs: Context & Participant Retention. *European Journal of Open, Distance and E-Learning*, p. 23.
- Lacerda, D. P., Dresch, A., Proença, A., & Antunes Júnior, J. A. V. (2013). Design Science Research: Método de pesquisa para a engenharia de produção. *Gestão & Produção*, 20(4), 741–761. <https://doi.org/10.1590/S0104-530X2013005000014>
- Liu, B. (2010). Sentiment Analysis and Subjectivity. *Handbook of Natural Language Processing*, (2), 38.
- Liu, B. (2012). *Sentiment analysis and opinion mining*. San Rafael: Morgan & Claypool.
- Moreno-Marcos, P. M., Alario-Hoyos, C., Munoz-Merino, P. J., Estevez-Ayres, I., & Kloos, C. D. (2018). Sentiment analysis in MOOCs: A case study. *2018 IEEE Global Engineering Education Conference (EDUCON)*, 1489–1496. <https://doi.org/10.1109/EDUCON.2018.8363409>

9. Referências.

Pinto, Herbert & Rocio, Vitor. (2019). Combining Sentiment Analysis Scores to Improve Accuracy of Polarity Classification in MOOC Posts. 10.1007/978-3-030-30241-2_4.

Robinson, C., Yeomans, M., Reich, J., Hulleman, C., & Gehlbach, H. (2016). Forecasting student achievement in MOOCs with natural language processing. *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge - LAK '16*, 383–387. <https://doi.org/10.1145/2883851.2883932>

Rossi, L. A., & Gnawali, O. (2014). Language independent analysis and classification of discussion threads in Coursera MOOC forums. *Proceedings of the 2014 IEEE 15th International Conference on Information Reuse and Integration (IEEE IRI 2014)*, 654–661. <https://doi.org/10.1109/IRI.2014.7051952>

Russell, S. J., Norvig, P., & Davis, E. (2010). *Artificial intelligence: A modern approach* (3rd ed). Upper Saddle River: Prentice Hall.

Santos, F. de P., Silveira, I. F., & Lechugo, C. P. (2017). Análise da percepção dos alunos sobre as práticas docentes por meio da mineração de dados educacionais. *Revista Espacios*, 38(5), 15.

Siemens, G. (2013). Learning Analytics: The Emergence of a Discipline. *American Behavioral Scientist*, 57(10), 1380–1400. <https://doi.org/10.1177/0002764213498851>

Simon, H. A. (1996). *The sciences of the artificial* (3. ed., [Nachdr.]). Cambridge, Mass.: MIT Press.

Tsytsarau, M., & Palpanas, T. (2012). Survey on mining subjective data on the web. *Data Mining and Knowledge Discovery*, 24(3), 478–514. <https://doi.org/10.1007/s10618-011-0238-6>

9. Referências.

Vergara, S., El-Khouly, M., Tantawi, M. E., Marla, S., & Sri, L. (2017). *Building Cognitive Applications with IBM Watson Services: Volume 7 Natural Language Understanding*. 112.

Wang, L., Hu, G., & Zhou, T. (2018). Semantic Analysis of Learners' Emotional Tendencies on Online MOOC Education. *Sustainability*, 10(6), 1921. <https://doi.org/10.3390/su10061921>

Wen, M., Yang, D., & Rosé, C. P. (2014). *Sentiment Analysis in MOOC Discussion Forums: What does it tell us?* 8.

Wong, J.-S., Pursel, B., Divinsky, A., & Jansen, B. J. (2015). An Analysis of MOOC Discussion Forum Interactions from the Most Active Users. In N. Agarwal, K. Xu, & N. Osgood (Orgs.), *Social Computing, Behavioral-Cultural Modeling, and Prediction* (Vol. 9021, p. 452–457). https://doi.org/10.1007/978-3-319-16268-3_58<https://doi.org/10.1145/2883851.2883932>

Anexo I – Programas desenvolvidos em Python para a pesquisa.

Anexo I – Programas desenvolvidos em *Python* para a pesquisa.

roda_aws.py

```
1 # Sentimoooc - conecta ao bd e insere dados do algoritmo - Amazon AWS
2 # Autor: Herbert Larooca - MISE 2018/2019 - 14/03/2019
3 # Efetua a leitura das mensagens do bd sequencialmente, envia para a Amazon AWS
4 # e grava o retorno (polaridade e score) no BD
5
6 import boto3
7 import psycopg2
8 import json
9
10 client = boto3.client(service_name='comprehend', region_name='us-east-1')
11
12 conn = psycopg2.connect("host=localhost dbname=sentimoooc user=postgres password=*****")
13 cur1 = conn.cursor()
14 cur2 = conn.cursor()
15 sql1 = "SELECT id, mensagem, pol_aws, idioma FROM mensagem ORDER BY id"
16 cur1.execute(sql1)
17 linha = cur1.fetchone()
18 nlin = 0
19 while linha is not None:
20     id = linha[0]
21     msg = linha[1]
22     pol = linha[2]
23     idioma = linha[3].strip(" ")
24     if pol == None :
25         ret = client.detect_sentiment(Text=msg, LanguageCode=idioma)
26         label = ret["Sentiment"]
27         label = label.lower()
28         label = label.capitalize()
29         score = ret["SentimentScore"][label]
30         # Somente a api amazon categoriza a polaridade como mixed.
31         # Para se adequar às outras APIS
32         # troca-se mixed por neutral.
33         if label == "Mix" :
34             label = "Neu"
35         sql2 = "UPDATE mensagem SET pol_aws = %s, score_aws = %s WHERE id = %s"
36         cur2.execute(sql2, (label[:3].lower(), score, id))
37         conn.commit()
38         nlin = nlin + 1
39         print("Processando Linha/MSG N°:",nlin,"/"+str(id))
40         linha = cur1.fetchone()
41 cur2.close()
42 cur1.close()
43 conn.close()
```

Anexo I – Programas desenvolvidos em Python para a pesquisa.

roda_azure.py

```
01 # Sentimoooc - conecta ao bd e insere dados do algoritmo - MicroSoft Azure
02 # Autor: Herbert Larooca - MISE 2018/2019 - 14/03/2019
03 # Efetua a leitura das mensagens do bd sequencialmente, envia para o Microsoft Azure
04 # e grava o retorno (polaridade e score) no BD
05
06 import psycopg2
07 import requests
08 import json
09
10 subscription_key1 = '*****'
11 subscription_key2 = '*****'
12 assert subscription_key1
13 text_analytics_base_url =
14 "https://westcentralus.api.cognitive.microsoft.com/text/analytics/v2.0/sentiment"
15
16 conn = psycopg2.connect("host=localhost dbname=sentimoooc user=postgres password=*****")
17 cur1 = conn.cursor()
18 cur2 = conn.cursor()
19 sql1 = "SELECT id, mensagem, pol_azul, idioma FROM mensagem ORDER BY id"
20 cur1.execute(sql1)
21 linha = cur1.fetchone()
22 nlin = 0
23 while linha is not None:
24     id = linha[0]
25     msg = linha[1]
26     pol = linha[2]
27     idioma = linha[3].strip()
28     if pol == None :
29         documents = {'documents' : [{'id': '1', 'language': idioma, 'text': msg}]}
30         headers = {"Ocp-Apim-Subscription-Key": subscription_key1}
31         response = requests.post(text_analytics_base_url, headers=headers,
32 json=documents)
33         ret=response.json()
34         score = ret ["documents"][0]["score"]
35         if score < .5: label = 'neg'
36         if score == 0.0: label = 'neu'
37         if score >= .5: label = 'pos'
38         sql2 = "UPDATE mensagem SET pol_azul = %s, score_azul = %s WHERE id = %s"
39         cur2.execute(sql2, (label, score, id))
40         conn.commit()
41         nlin = nlin + 1
42         print("Processando Linha/MSG N°:",nlin,"/" +str(id))
43     linha = cur1.fetchone()
44 cur2.close()
45 cur1.close()
46 conn.close()
```

Anexo I – Programas desenvolvidos em Python para a pesquisa.

roda_google.py

```
01 # Sentimoooc - conecta ao bd e insere dados do algoritmo - Google Cloud Natural Language
02 # Autor: Herbert Larooca - MISE 2018/2019 - 01/04/2019
03 # Efetua a leitura das mensagens do bd sequencialmente, envia para o Google Cloud
04 Natural Language
05 # e grava o retorno (polaridade e score) no BD
06
07
08 import psycopg2
09
10 # Imports the Google Cloud client library
11 from google.cloud import language
12 from google.cloud.language import enums
13 from google.cloud.language import types
14
15 conn = psycopg2.connect("host=localhost dbname=sentimoooc user=postgres password=****")
16 cur1 = conn.cursor()
17 cur2 = conn.cursor()
18 sql1 = "SELECT id, mensagem, pol_goo, idioma FROM mensagem ORDER BY id"
19 cur1.execute(sql1)
20 linha = cur1.fetchone()
21 nlin = 0
22 while linha is not None:
23     id      = linha[0]
24     msg     = linha[1]
25     pol    = linha[2]
26     idioma = linha[3]
27     mag    = 0
28     if pol == None :
29
30         # Instantiates a client
31         client = language.LanguageServiceClient()
32         # The text to analyze
33         document = types.Document(
34             content=msg,
35             type=enums.Document.Type.PLAIN_TEXT)
36         # Detects the sentiment of the text
37         sentiment = client.analyze_sentiment(document=document).document_sentiment
38         score = sentiment.score
39         mag = sentiment.magnitude
40         if score > 0.1 :
41             label = 'pos'
42         elif score == 0 :
43             label = 'neu'
44         elif score < 0 :
45             label = 'neg'
46
47         sql2 = "UPDATE mensagem SET pol_goo = %s, score_goo = %s WHERE id = %s"
48         cur2.execute(sql2, (label, score, id))
49         conn.commit()
50         nlin = nlin + 1
51         print("Processando Linha/MSG N°:",nlin,"/"+str(id))
52     linha = cur1.fetchone()
53 cur2.close()
54 cur1.close()
55 conn.close()
```

Anexo I – Programas desenvolvidos em Python para a pesquisa.

roda_ibm.py

```
01 # Sentimooc - conecta ao bd e insere dados do algoritmo - IBM NLU
02 # Autor: Herbert Laroça - MISE 2018/2019 - 11/03/2019
03 # Efetua a leitura das mensagens do bd sequencialmente, envia para o IBM NLU
04 # e grava o retorno (polaridade e score) no BD
05
06 import json
07 from watson_developer_cloud import NaturalLanguageUnderstandingV1
08 from watson_developer_cloud.natural_language_understanding_v1 import Features,
09 SentimentOptions
10 import psycopg2
11
12 conn = psycopg2.connect("host=localhost dbname=sentimooc user=postgres password=*****")
13 cur1 = conn.cursor()
14 cur2 = conn.cursor()
15 sql1 = "SELECT id, mensagem, pol_ibm FROM mensagem ORDER BY id"
16 cur1.execute(sql1)
17 linha = cur1.fetchone()
18 nlin = 0
19 while linha is not None:
20     id = linha[0]
21     msg = linha[1]
22     pol = linha[2]
23     if pol == None :
24         nlu = NaturalLanguageUnderstandingV1(version='2018-11-16',
25         iam_apikey='*****', url='https://gateway.watsonplatform.net/natural-language-
26         understanding/api')
27     response =
28     nlu.analyze(text=msg, features=Features(sentiment=SentimentOptions())).get_result()
29     ret=json.loads(json.dumps(response))
30     score = ret["sentiment"]["document"]["score"]
31     label = ret["sentiment"]["document"]["label"]
32     idioma = ret["language"]
33     sql2 = "UPDATE mensagem SET pol_ibm = %s, score_ibm = %s, idioma = %s WHERE id =
34     %s"
35     cur2.execute(sql2, (label[:3], score, idioma, id))
36     conn.commit()
37     nlin = nlin + 1
38     print("Processando Linha/MSG N°:",nlin,"/" +str(id))
39     linha = cur1.fetchone()
40 cur2.close()
41 cur1.close()
42 conn.close()
```

Anexo I – Programas desenvolvidos em Python para a pesquisa.

roda_media_ponderada.py

```
01 # Sentimooc - conecta ao bd e calcula a media ponderada por polaridade
02 # Autor: Herbert Laroca - MISE 2018/2019 - 14/09/2019
03 import psycopg2
04 conn = psycopg2.connect("host=localhost dbname=sentimooc user=postgres password=****")
05 cur1 = conn.cursor()
06 cur2 = conn.cursor()
07 sql1 = "SELECT id,
08 score_aws_norm,score_azu_norm,score_ibm,score_goo,pol_aws,pol_azu,pol_ibm,pol_goo FROM
09 mensagem ORDER BY id"
10 cur1.execute(sql1)
11 linha = cur1.fetchone()
12 nlin = 0
13 neutro = 0.08
14 while linha is not None:
15     peso = 0
16     id = linha[0]
17     scaws = linha[1]
18     scazu = linha[2]
19     scibm = linha[3]
20     scgoo = linha[4]
21     pol = [linha[5],linha[6],linha[7],linha[8]]
22     pesoaws = pol.count(linha[5])
23     pesoazu = pol.count(linha[6])
24     pesoibm = pol.count(linha[7])
25     pesogoo = pol.count(linha[8])
26     scpond = (scaws*pesoaws + scazu*pesoazu + scibm*pesoibm + scgoo*pesogoo) / (pesoaws +
27     pesoazu + pesoibm + pesogoo)
28     if scpond < 0 :
29         polpond = 'neg'
30     if scpond > 0 :
31         polpond = 'pos'
32     if scpond >= -neutro and scpond <= neutro :
33         polpond = 'neu'
34     sql2 = "UPDATE mensagem SET score_avga_pond = %s, pol_avga_pond = %s WHERE id = %s"
35     cur2.execute(sql2, (scpond, polpond, id))
36     conn.commit()
37     nlin = nlin + 1
38     linha = cur1.fetchone()
39 cur2.close()
40 cur1.close()
41 conn.close()
```
