

## A análise de emoções na predição do desempenho acadêmico The analysis of emotions for academic performance prediction

**William Marinho Santos** Mestre em Governança, Tecnologia e Inovação. Universidade Católica de Brasília (UCB).  
<http://orcid.org/0000-0003-3895-5200> willian.marinho2006@gmail.com

**Helga Cristina Hedler** Doutora em Psicologia Social, do Trabalho e das Organizações. Universidade Católica de Brasília (UCB).  
<http://orcid.org/0000-0002-3510-1624> helgachedler@gmail.com

**Edilson Ferneda** Doutor em Ciência da Computação. Universidade Católica de Brasília (UCB).  
<https://orcid.org/0000-0003-4164-5828> eferneda@gmail.com

**Hercules Antonio do Prado** Doutor em Ciência da Computação. Universidade Católica de Brasília (UCB).  
<https://orcid.org/0000-0002-8375-0899> prado.hercules@gmail.com

**Breno Giovanni Adaid Castro** Doutor em Administração. Instituto de Educação Superior de Brasília (IESB).  
<https://orcid.org/0000-0002-9856-4263> brenoadaid@gmail.com

### RESUMO

A identificação de emoções, principalmente nos cursos da modalidade de Educação a Distância (EAD), pode ser relevante para a gestão do ambiente visando a melhoria do desempenho acadêmico do aluno. Este estudo tem como objetivo propor uma ferramenta computacional para a identificação de relações entre emoções predominantes no ambiente de aprendizado e o desempenho acadêmico dos estudantes no âmbito da EAD. Para tal, foram utilizadas as interações textuais em ambientes virtuais de aprendizagem (AVA) ocorridas entre professores e alunos. Foram utilizadas técnicas de processamento de linguagem natural para análise de emoções sobre um corpus extraído das bases de dados de um AVA, complementado por dados de identificação e rendimento obtidos no sistema de gestão acadêmica. O corpus inicial foi composto por 1602 mensagens, com nível de granularidade de sentença, trocadas no contexto uma disciplina oferecida em 2019. Destas, foram selecionadas 1347 (84,03%), que puderam ser classificadas de acordo com a polaridade dos sentimentos (Positivo, Negativo ou Neutro) e emoções predominantes (Tristeza, Alegria, Medo, Aversão e Raiva). A ferramenta proposta foi construída sobre as APIs do ambiente de inteligência artificial Watson da IBM. Essa ferramenta tem o potencial de fornecer a tutores e gerentes informações úteis para a tomada de decisões e mitigação de possíveis problemas.

**Palavras-chave:** análise de emoções; mineração de dados educacionais; desempenho acadêmico.

### ABSTRACT

Identification of emotions, especially in Distance Learning (DL) courses, can be relevant for managers who seek for improving the student's academic performance. This study aims to propose a computational tool for the identification of relationships between predominant emotions in the learning environment and the academic performance of students in the context of distance learning. For this, textual interactions in virtual learning environments (VLE) between teachers and students were used. Natural language processing techniques were used to analyze emotions in a corpus extracted from the databases of a VLE, complemented by identification and performance data obtained from the academic management system. The initial corpus consisted of 1602 messages, with a level of sentence granularity, exchanged in the context of a discipline offered in 2019. From these, 1347 (84.03%) were selected, which could be classified according to the polarity of feelings (Positive, Negative or Neutral) and predominant emotions (Sadness, Joy, Fear, Aversion and Anger). The proposed tool was built over the APIs from IBM's Watson artificial intelligence environment. This tool has the potential to provide tutors and managers with useful information to make decisions to mitigate potential problems

**Keywords:** emotion analysis; educational data mining; academic performance.

Recebido em 27/09/2021. Aprovado em 14/11/2021. Avaliado pelo sistema double blind peer review. Publicado conforme normas da ABNT.  
<https://doi.org/10.22279/navus.2022.v12.p01-15.1690>

## 1 INTRODUÇÃO

A ampla disponibilidade de dados a partir das interações humanas em plataformas digitais levou a um crescente interesse por métodos para explorar o conhecimento útil relevante em diversas áreas, incluindo a Educação (HECKMAN; KAUTZ, 2013; BOBÓ *et al.*, 2019). A análise de dados educacionais é cada vez mais usada para subsidiar políticas e práticas nesta área (GHAZARIAN; KWON, 2015).

A Mineração de Dados Educacionais (MDE) têm se destacado como ferramenta para apoiar o processo de avaliação e previsão do desempenho acadêmico, sendo considerados relevantes aspectos que vão além das habilidades cognitivas (LIPNEVICH; ROBERTS, 2012). Neste sentido, estados emocionais desempenham um papel importante na formação dos alunos (SUERO-MONTERO, 2014) ou ainda a regulação emocional (ANDRÉS *et al.*, 2017).

Análise de Sentimentos (AS) “é o campo de estudo que analisa as opiniões, sentimentos, avaliações, atitudes e emoções das pessoas em relação a entidades como produtos, serviços, organizações, indivíduos, eventos e seus aspectos” (LIU, 2012). Em particular, a AS em textos ganhou impulso com a difusão das redes sociais em ambiente Web e vem promovendo o desenvolvimento de métodos computacionais capazes de identificar características afetivas em textos (LIU, 2015; MORAIS *et al.*, 2017). Nesse contexto, AS guarda uma interseção com a área de Processamento de Linguagem Natural (PLN).

No contexto educacional, esse tipo de análise é capaz de identificar o estado emocional do aluno durante uma sessão de aprendizagem ou atividade, podendo fornecer ao tutor - humano ou sistema automatizado - mais recursos para uma melhor experiência de aprendizagem, de modo, inclusive a influenciar a tomada de decisão dos tutores no planejamento educacional (SUERO-MONTERO, 2014).

Os fóruns online tornaram-se uma das ferramentas de comunicação mais utilizadas nos Ambientes Virtuais de Aprendizagem (AVA) e um fator fundamental do processo de aprendizagem, especialmente na modalidade de Educação a Distância (EAD), pois, podem proporcionar uma forma de interação que motiva os estudantes para a busca e o compartilhamento do conhecimento. Ao se analisar dados relacionados à participação de alunos em fóruns online com técnicas de mineração de texto, é possível observar suas atitudes em relação ao curso e seus recursos (KAGKLIS *et al.*, 2015). Além disso, pode-se criar modelos que caracterizem perfis de comportamento por meio de AS ao longo do tempo e, finalmente, detectar se e como isso afetou seu processo de aprendizagem. O conhecimento obtido por essa abordagem pode fornecer aos tutores informações sobre a estrutura e o conteúdo das mensagens trocadas pelos alunos, os padrões de interação entre eles e a tendência de polaridade de sentimentos durante o curso, de modo a subsidiar o processo de gestão educacional. No entanto, é preciso ter claro que fatores não acadêmicos também desempenham um papel proeminente na explicação da variação de desempenho escolar de estudantes, como aqueles mensurados pelo *Programme for International Student Assessment (PISA)* (MENDEZ, 2015).

Mattar, Rodrigues e Graciani (2020), em uma revisão sistemática sobre as competências e funções dos tutores online, destacam que os estudos têm apontado: (i) competências gerenciais, (ii) saberes disciplinares, (iii) saberes pedagógicos, (iv) habilidade de comunicação, (v) competências socioafetivas e (vi) habilidades tecnológicas. As funções básicas do tutor em EaD seriam de natureza gerenciais, pedagógicas e sociais. Bobó *et al.* (2019) destacam que os estudos sobre análises de sentimentos têm usado geralmente as redes sociais ou os fóruns do AVA como fonte de dados para as suas aplicações. Os AVA trouxeram novas perspectivas para o processo de ensino-aprendizagem, requerendo dos docentes um olhar inovador, não somente na forma como se entende a educação, mas principalmente no modo como essa ocorre na prática. A aplicação da AS nesse contexto abriu novas perspectivas de pesquisa e aplicação com reflexos tanto na gestão do processo educacional quanto no próprio desempenho discente.

No contexto educacional, a detecção imediata de problemas emocionais ou da necessidade de atenção particular é importante para um feedback imediato e personalizado (RODRIGUEZ; ORTIGOSA; CARRO, 2012). O uso de AS a partir de textos produzidos pelos alunos torna-se menos invasivo do que, por exemplo, por meio de entrevistas pessoais.

Em suma, o desenvolvimento de modelos preditivos do desempenho acadêmico a partir da identificação de manifestações afetivas na dinâmica interativa dos AVA mostra-se relevante para os atores envolvidos nos processos de ensino-aprendizagem.

Busca-se aqui contribuir para a identificação de padrões emocionais de estudantes com base nas interações textuais em AVA que possam subsidiar a construção de um modelo preditivo de desempenho acadêmico no âmbito da EAD. O presente estudo combina teoria e métodos de pesquisa da Psicologia Social e da personalidade humana com técnicas analíticas de PLN como uma aproximação das emoções encontradas em textos escritos.

## 2 REVISÃO DE LITERATURA

Autores como Feng *et al.* (2017), Tao, Fang (2020), Song *et al.* (2014) defendem que a identificação de emoções em atividades virtuais de ensino-aprendizagem deveria considerar elementos advindos de reconhecimento facial e de fala, juntamente com os textos produzidos pelo estudante. Imani, Montazer (2020), Gonçalves *et al.* (2017) reconhecem a importância dos sentimentos e emoções no desempenho do estudante e propõem sua caracterização com base em dados relativos à expressão facial, movimentos corporais, gestos, fala e postura capturados por sensores.

As emoções positivas trazem confiança para os alunos no aprendizado, e as negativas podem levar ao desinteresse e à desistência (CUI; GOU, 2019). Wang, Hu e Zhou (2018) apontam que os alunos são mais propensos a emoções negativas quando encontram dificuldades na aprendizagem, tendendo a perder o interesse no curso.

A carência de soluções mais eficientes para a detecção dos estados emocionais em texto nas redes sociais e AVA tem sido reconhecida pela comunidade de pesquisa (IMANI; MONTAZER, 2019). Lo *et al.* (2017) destacam limitações dos algoritmos para a identificação de sentimentos e emoções em textos informais, que normalmente contêm abreviações, gírias e palavras em diferentes idiomas, formas bastante usadas em AVA ou redes sociais. Apesar de algumas divergências entre os autores em relação à eficácia de alguns métodos de identificação de sentimentos e emoções, é reconhecida a importância e os benefícios da AS para o aprendizado e desempenho dos alunos, como por exemplo a detecção das variações de humor, medo e estresse nas dinâmicas interpessoais entre o professor e o aluno, e entre este e os seus pares (WEINER, GRAHAM, 1984; MARQUEZ; ROMERO; VENTURA, 2010; WANG; HU; ZHOU, 2018).

Na Psicologia, os termos afeto, emoção e sentimento estão intimamente entrelaçados e muitas vezes são confundidos. Afeto é um termo mais genérico que engloba tanto emoções quanto sentimentos (ROBBINS, 2010). As emoções, por sua vez, são expressões afetivas intensas que emergem em determinadas situações (e.g., ver um amigo pode despertar o sentimento de felicidade; uma discussão pode levar ao sentimento de raiva). Normalmente, as emoções são de curta duração e acompanhadas de reações fisiológicas, tais como choro, aumento de batimentos cardíacos ou tremor nas pernas. Já sentimentos são estados afetivos menos intensos, porém mais duradouros do que as emoções e que não requerem um estímulo contextual para se manifestarem. Miguel (2015, p. 153) complementa que “as emoções não são mais compreendidas como uma reação única, [...] são uma condição complexa e momentânea que surge em experiências de caráter afetivo, provocando alterações em várias áreas do funcionamento psicológico e fisiológico, preparando o indivíduo para a ação”.

Emoções podem se transformar em sentimentos quando se abstrai a causa que ativou a reação afetiva. Segundo Robbins (2005, p. 93), a relação entre afeto, emoções e sentimentos pode ser compreendida da seguinte forma:

- Afeto: definido como uma ampla extensão de sensações pelas pessoas, o afeto pode ser vivenciado na forma de emoções e de sentimentos.
- Emoções: são causadas por um evento específico; de breve duração; são específicas e de várias naturezas (muitas emoções específicas como raiva, medo, tristeza, aversão ou surpresa); normalmente são acompanhadas de expressões faciais e reações físicas e, por último, desencadeiam ações.
- Sentimentos: geralmente um sentimento não está relacionado a uma causa específica; tem duração maior que as emoções, são mais gerais (possuem duas dimensões principais – afetividade positiva e afetividade negativa – que são compostas de múltiplas dimensões); geralmente não são demonstrados por meio de expressões ou reações físicas específicas e são de natureza cognitiva.

Nesse sentido, a regulação das emoções envolve os processos que permitem ao indivíduo monitorar, avaliar e modificar a natureza e curso de uma emoção, a fim de cumprir seus objetivos e responder de forma apropriada as demandas do ambiente (ANDRÉS *et al.*, 2017). Entende-se que o desafio está em regular as próprias emoções para obter o desempenho desejado.

## 2.1 Modelo de emoções

Diferentes teorias científicas tentam explicar a diversidade de fenômenos relativos ao afeto. Essas teorias originaram três principais modelos de emoções: os modelos discretos ou categóricos, os dimensionais e os baseados na teoria Appraisal (DOSCIATTI, 2015).

Os modelos discretos tendem a agrupar as emoções em categorias, partindo do princípio de que as emoções são independentes. Dentre os modelos discretos, o mais difundido é o modelo de emoções básicas, proposto por Ekman (1992), que reconhece seis emoções básicas: alegria, tristeza, raiva, medo, repugnância e surpresa. De acordo com Libralon (2014), esses modelos partem do princípio de que as emoções podem ser facilmente identificadas por meio das expressões faciais. No Quadro 1 são apresentadas outras propostas de categorização de emoções.

Quadro 1 – Exemplos de categorização de emoções

Proponente	Categorias
McDougall (1926)	Raiva, repugnância, alegria, medo e espanto.
Watson (1930)	Medo, amor e raiva.
Arnold (1960)	Raiva, aversão, coragem, abatimento, desejo, desespero, medo, ódio, esperança, amor e tristeza.
Mowrer (1960)	Dor e prazer
Izard (1971)	Raiva, desprezo, repugnância, angústia, medo, culpa, interesse, alegria, vergonha e surpresa.
Plutchik (1980)	Confiança, raiva, expectativa, repugnância, alegria, medo, tristeza e surpresa.
Gray (1982)	Raiva, terror, ansiedade e alegria.
Panksepp (1982)	Expectativa, medo, fúria e pânico.
James (1884)	Medo, dor, amor e fúria.
Weiner e Graham (1984)	Felicidade e tristeza.

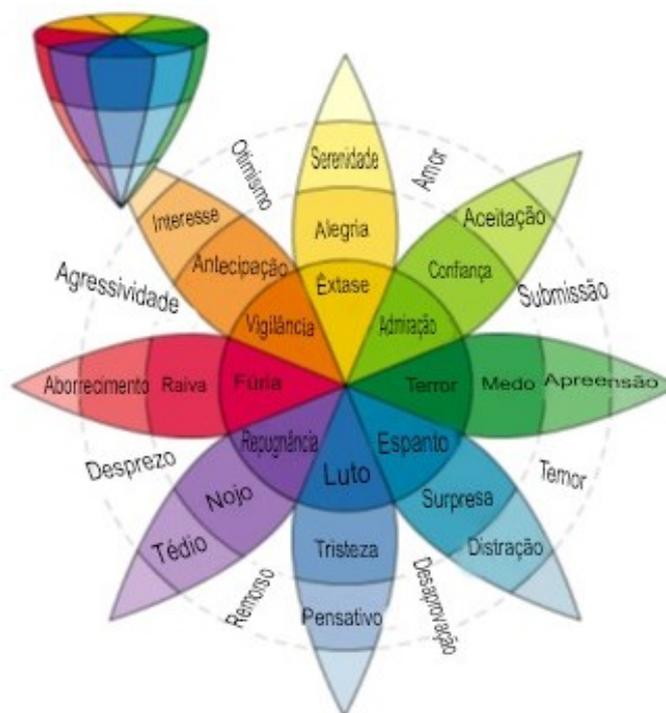
Fonte: os autores (2021)

Porém, os comportamentos afetivos não são suficientes e necessários para caracterizar todos os estados emocionais (PANKSEPP, 1998; KAGAN, 2003). A ansiedade, por exemplo, pode ser sentida sem qualquer alteração evidente no comportamento; nem todas as emoções são acompanhadas de expressões faciais (EKMAN, 1993; MIGUEL, 2015).

Os modelos dimensionais visam descrever a relação existente entre as categorias de emoções diferenciando-as de acordo com duas ou três características (modelos 2D ou 3D). Dentre os modelos 2D, o mais difundido é o modelo 'circumplexo' de afeto (RUSSELL, 1980), no qual as emoções se inter-relacionam em um círculo e são representadas em duas dimensões: valência (sentimentos agradáveis versus desagradáveis) e ativação (desperto versus sonolento). Cada experiência afetiva é consequência de uma combinação linear dessas duas dimensões que é, então, interpretada como uma emoção particular.

Os modelos 3D (PLUTCHIK, 1980) (Figura 1) baseiam-se em um contexto evolucionário e incluem oito emoções primárias: alegria, tristeza, raiva, medo, repugnância, surpresa, expectativa e confiança. As emoções posicionadas nos espaços em branco são a combinação de duas emoções primárias.

Figura 1 – Modelo de emoções de Plutchik.



Fonte: adaptado de Plutchik (1980)

Os modelos de emoções baseados na teoria Appraisal consideram as emoções como resultado de avaliações subjetivas de um determinado evento ou situação que está acontecendo em um momento específico (LAZARUS, 1991).

Do ponto de vista computacional, a compreensão das emoções refere-se à capacidade não apenas de se detectar a informação emocional, mas também armazenar, processar, construir e manter um modelo emocional do usuário (LIBRALON, 2014).

## 2.2. Relatos sobre análise de sentimentos e desempenho acadêmico

Para ilustrar o desenvolvimento das pesquisas na temática, seguem algumas pesquisas que mostram o desenvolvimento, os avanços e desafios na área. Em pesquisa comparativa entre a análise de sentimentos realizada por diversas ferramentas analíticas e a análise humana, verificou-se que há diferenças na categorização da intensidade dos sentimentos por cada método. Assim, “as ferramentas utilizadas classificaram mais de 40% dos comentários como neutros, a análise dos autores das mensagens indicou que 71% dos comentários eram positivos” (MOREIRA *et al.*, 2016, p. 441). Os autores destacam a necessidade de melhoria na acurácia dos métodos.

Andrés *et al.* (2017), em uma revisão sistemática sobre a regulação emocional (RE) e o desempenho acadêmico, destacam que as habilidades de RE mais estudadas está o reconhecimento de emoções, a tolerância ao estresse e a modificação das reações emocionais. A regulação de emoções refere-se aos processos que permitem à pessoa monitorar, avaliar, modificar a natureza de uma emoção, com a finalidade de atingir seus objetivos e responder de forma adequada as demandas do ambiente. Os autores concluíram que os alunos que conseguem controlar as suas emoções teriam uma vantagem em seu desempenho quando comparados com aqueles que não conseguem. Concluem também que as estratégias e habilidades de regulação de emoções apresentam associações positivas em tarefas de leitura e matemática e em atividades que exigem competências gerais, como seguir instruções.

Morais *et al.* (2017) realizaram um mapeamento sistemático de literatura dos últimos 15 anos na área de computação afetiva no contexto de informática na educação. Os resultados indicaram que os estados afetivos mais estudados são emoções, personalidade e humor. Quanto às fontes e ferramentas mais usadas na

detecção dos estados afetivos dos alunos nos trabalhos de pesquisa brasileiros foram: o comportamento observável, os textos e as escalas de personalidade. Ao indagar o que o sistema faz com a informação da detecção do estado afetivo do aluno verificaram que os sistemas usam algumas técnicas como agrupar os alunos com base em seu estado afetivo, expressar emoções por meio de um agente animado, e mensagens motivacionais. Entretanto, destacam que a maioria dos trabalhos ainda carece de melhor demonstração empírica dos resultados.

Bobó *et al.* (2019, p. 254) consideram que o desempenho acadêmico pode ser afetado diretamente pela análise de sentimentos quando apropriados os seus achados para o planejamento educacional. Os autores, em mapeamento sistemático da literatura, trouxeram indicativos sobre o uso da análise de sentimentos na educação. Dentre os achados destaca-se seu uso em objetivos como: (i) melhoria do processo ensino-aprendizagem; (ii) avaliações de docentes, de curso ou de ensino; (iii) melhoria das funções dos ambientes virtuais de aprendizagem e (iv) compor sistemas de recomendação de conteúdos educacionais. Além disso, verificaram que a classificação mais usada tem sido uma com duas escalas de sentimentos (Positivo, Negativo e Neutro; ou Positivo e Negativo). Os tipos de emoções mais consideradas tem sido raiva, tristeza, medo, alegria, confusão, tédio e nojo – emoções consideradas negativas e que talvez isso seja “um indicativo da preocupação dos autores em detectar e sanar problemas ligados à educação”.

### 2.3 Análise de sentimentos

A AS se dedica a analisar automaticamente estados afetivos a partir de documentos escritos em linguagem natural, baseados em categorias de emoção. É o campo de estudo que analisa opiniões, sentimentos, avaliações, atitudes e emoções das pessoas em relação a entidades e seus atributos expressos de forma textual. A AS é feita a partir da expressão das emoções e sentimentos das pessoas em linguagem natural. (LIU, 2015)

Do ponto de vista do PLN, busca-se captar palavras que expressem emoção com base em um dos três modelos citados: discretos, dimensionais e baseados na teoria Appraisal. A detecção de emoções é um processo complexo tanto para o ser humano como para sistemas computacionais. Segundo Liu (2015), os principais desafios que dificultam a tarefa de AS em textos são:

- As emoções, sentimentos e opiniões expressos nos textos são comumente apresentados de forma subjetiva;
- Os textos se apresentam em diferentes formatos e de forma não estruturada;
- A maioria dos textos são escritos em uma linguagem informal e muitos contêm gírias, sarcasmo, ironia e emoticons (ícones de emoções usados na interação em redes sociais virtuais);
- Em alguns casos, os textos apresentam limitação de tamanho, a exemplo do Twitter;
- Normalmente, os métodos desenvolvidos são sensíveis ao domínio ou ao idioma.

Para Liu (2015), a AS em textos pode ser aplicada em três níveis de granularidade: documento, sentença ou algum aspecto específico em discussão.

A AS pode ser realizada do ponto de vista do autor, que expressa a emoção e o sentimento nas palavras do texto, ou dos leitores, que leem o texto e interpretam as emoções e sentimentos nele contidos. Nesta pesquisa foi adotado o ponto de vista do autor.

### 2.4 Identificação de emoções em textos

As abordagens baseadas em Aprendizagem de Máquina (AM) e em léxico são as mais utilizadas para solucionar os problemas de AS em textos. A abordagem baseada em AM está dividida em supervisionada e não supervisionada. O primeiro caso se aplica quando se tem um conjunto de textos rotulados com os sentimentos previamente identificados. Na ausência de rótulos, pode-se aplicar o aprendizado não supervisionado para se tentar identificar conjuntos de sentimentos afins. Cada modalidade de AM possui diversos algoritmos para a criação de modelos em função dos dados disponíveis e dos objetivos da aplicação.

A abordagem baseada em léxico depende da existência de um conjunto de termos identificados com emoções. Pode ser baseada em dicionário ou em um corpus<sup>1</sup>. Na abordagem baseada em dicionário, um pequeno conjunto de termos emocionais é recolhido manualmente e cada termo possui uma emoção associada. Na abordagem baseada em corpus, uma lista de termos emocionais sementes é utilizada para encontrar outros termos emocionais em um grande corpus de domínio (LIU, 2012).

### 3. MÉTODO PROPOSTO

Existem iniciativas de pesquisa para o desenvolvimento de algoritmos mais eficientes para a detecção de estados emocionais a partir de interações em redes sociais, em particular, associadas a AVA (LIU, 2010; 2012; 2015). Com o objetivo de construir um modelo preditivo de desempenho acadêmico no âmbito da EAD a partir do comportamento emocional de estudantes em um AVA, foi desenvolvida uma ferramenta de preparação, pré-processamento e processamento dos dados, com capacidade de interagir com o ambiente *Watson*, da IBM.

Para produzir subsídios a um modelo preditivo de desempenho acadêmico, foram utilizadas (i) técnicas de MDE para coleta e análise de dados educacionais (GHAZARIAN; KWON, 2015), (ii) PLN para isolar, quantificar e descrever de forma qualificativa as emoções encontradas em textos escritos pelos alunos e (iii) Regressão Linear Múltipla para a predição do desempenho acadêmico dos alunos (YANG *et al.*, 2018).

Os métodos aplicados na análise a ser realizada pela ferramenta consistem das seguintes etapas:

**Compreensão do domínio do problema.** Essa etapa inicial envolve pensar cuidadosamente sobre o cenário de uso, entender o problema a ser resolvido e determinar os objetivos do projeto. Esses objetivos são estruturados em uma ou mais subtarefas da Ciência de Dados (CD) e, assim, a seleção inicial das ferramentas do CD (por exemplo, classificação e estimativa) pode ser realizada em etapa posterior do processo. Após isto, uma descrição do domínio do problema é gerada.

**Coleta e compreensão dos dados.** Esta etapa inclui a coleta dos dados disponíveis e a decisão de quais serão necessários (eg, remetente e destinatário da mensagem, data e hora da postagem e conteúdo da mensagem). Nesta pesquisa optou-se por analisar os registros (*log*) da interação entre professor ou tutor e alunos no AVA a fim de produzir inferências sobre os estados emocionais detectados e as avaliações de desempenho acadêmico registradas no Sistema de Gestão Acadêmica (SGA). Portanto, o estudo se baseará em duas fontes de dados: o SGA (para gerar perfis de alunos, com as médias de notas obtidas) e o AVA (para avaliar os logs da atividade do usuário em cursos, fóruns e grupos).

**Preparação dos dados.** Essa etapa envolve manipular e converter os dados brutos em formatos adequados que atendam aos requisitos de entrada específicos para as ferramentas de CD. Por exemplo, algumas técnicas de CD são projetadas para dados categóricos, enquanto outras tratam apenas valores numéricos. Exemplos típicos de manipulação incluem conversão ou transformação de dados em diferentes tipos ou a derivação de novos atributos. Os resultados são geralmente convertidos em um formato tabular para a próxima etapa (CIOS *et al.*, 2007). Para esta pesquisa realizaram-se sete tarefas de pré-processamento: (i) conversão dos dados para o formato apropriado; (ii) agregação / integração de dados de diferentes fontes; (iii) limpeza de dados, com a detecção e tratamento de dados faltantes, inconsistentes ou irrelevantes; (iv) identificação de professores e alunos; (v) seleção de atributos / variáveis, escolhendo um subconjunto relevante; (vi) amostragem; e (vii) transformação de dados, com a derivação de novos atributos.

**Identificação de emoções e sentimentos.** Nesta etapa, os textos são apresentados à ferramenta de análise, que retorna os textos agora rotulados com os respectivos sentimentos e emoções. Entretanto, para algumas frases, a ferramenta não consegue associar emoções ou sentimentos.

**Avaliação do conhecimento descoberto.** A etapa de avaliação do conhecimento considera apenas as frases rotuladas. É feito um tratamento que identifica as emoções mais relevantes que, em conjunto, são mapeadas em sentimentos. As emoções obtidas são então comparadas com o rendimento acadêmico do estudante, buscando as emoções mais relacionadas com cada grupo de desempenho.

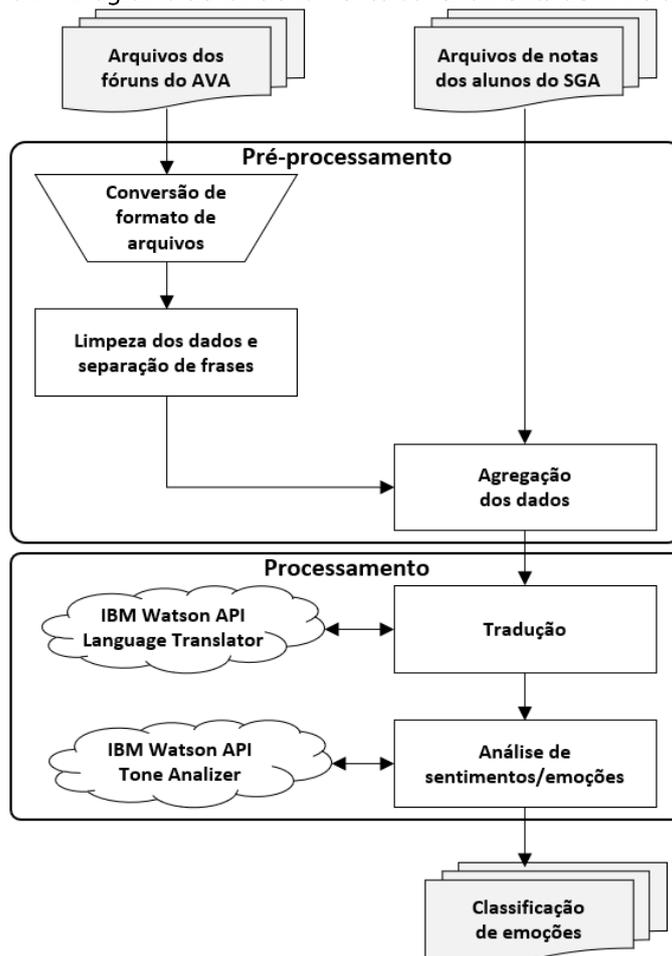
<sup>1</sup> *Corpus* é uma coletânea de textos que esteja em formato eletrônico em certo idioma.

**Aplicação.** O objetivo desta etapa é utilizar as relações entre emoções e rendimento acadêmico observadas na etapa anterior para a criação de um modelo preditivo para suporte à gestão. A ideia é que os gestores, de posse de informações sobre a interação dos alunos no AVA, possam prever seus desempenhos e orientar ações de mitigação ou incentivo. No entanto, é importante observar que barreiras como resistência individual e de grupo à inovação e mudança podem dificultar a aplicação do modelo (Romero e Ventura; 2010).

#### 4 FERRAMENTA DE MINERAÇÃO DE TEXTO

O escopo da ferramenta desenvolvida para essa pesquisa contempla basicamente o processamento dos arquivos da instituição observada, com foco na análise de sentimentos e emoções das interações entre professor e aluno (Figura 2).

Figura 2 – Diagrama de funcionamento da ferramenta de mineração de texto



Fonte: os autores (2021)

Para a realização das análises de dados, foi implementada uma ferramenta para Mineração de Textos, aplicando-se o modelo de processo para a descoberta de conhecimento proposto por Cios *et al.* (2007). A ferramenta foi desenvolvida para ser executada no Sistema Operacional *Windows*, foi implementada em linguagem de programação C# (*C Sharp*), utilizando o ambiente de desenvolvimento integrado *Microsoft Visual Studio 2017 (Community Edition)* e bibliotecas de código do *.NET Framework 4.7.2*.

Foram utilizadas também as bibliotecas *EPPlus*, para geração dos resultados em planilhas eletrônicas (folhas de cálculo) no formato *Microsoft Excel*, assim como a biblioteca *RestSharp* para consumo de serviços *web*, utilizando o Protocolo de Transferência de Hipertexto (*HTTP*) e o padrão de arquitetura de *software* Transferência Representacional de Estado (*REST*) e formato de troca de dados Notação de Objeto Javascript (*JSON*).

Para identificação de sentimentos por meio de textos existem disponíveis no mercado diversas Interface de Programação de Aplicativos (API), porém para identificação de emoções por meio de textos, comercialmente, temos apenas a API *Got It AI*<sup>2</sup> e a API *IBM Watson Tone Analyzer*<sup>3</sup>. A fim de determinar a API mais adequada aos objetivos da pesquisa, realizamos um teste com algumas frases já classificadas na pesquisa de Dosciatti (2015), cujo corpus utilizado foi construído com textos extraídos de notícias do site [www.globo.com](http://www.globo.com). A metodologia utilizada para determinar a API mais eficiente foi identificar as emoções em cada sentença do texto, em seguida, calcular a média dos seus escores, eleger a emoção de maior pontuação como predominante no texto, e, por fim, comparar com o resultado encontrado na pesquisa de Dosciatti (2015) para as mesmas frases. Com base nesse critério a API *IBM Watson Tone Analyzer* foi a escolhida, pois apresentou 60% de assertividade enquanto a API *Got It AI* somente 40%.

Os métodos e materiais aplicados na análise a ser realizada pela ferramenta compõem as fases de: (i) Pré-processamento (*preparação dos dados*) e (ii) Processamento (*identificação de emoções e sentimentos*). As etapas de *compreensão do domínio do problema, coleta e compreensão dos dados, avaliação do conhecimento descoberto e aplicação* não são contempladas na ferramenta.

#### 4.1 Pré-processamento

Em projetos de análise de sentimentos a partir em textos, a fase de pré-processamento é uma fase crítica (HADDI; LIU; SHI, 2013). Para esta fase, são necessárias as notas de avaliações dos alunos de uma disciplina, bem como dos *logs* da interação destes com outros alunos e com o professor disponíveis no AVA. Com base na análise do conteúdo das mensagens trocadas e do resultado das notas, foi selecionada uma disciplina ofertada em um semestre para realização do estudo. Nesta fase, a ferramenta avalia a estrutura dos arquivos disponibilizados e os converte conversão para texto puro (livre de elementos não textuais como emoticons).

A limpeza de dados é realizada por meio de uma funcionalidade, disponível na ferramenta, para leitura dos arquivos texto e retirada de caracteres especiais. A funcionalidade identifica também a cadeia de caracteres ou de palavras que define os limites das postagens dos alunos nos fóruns do AVA. Foi implementada uma funcionalidade que agrega os dados de notas dos alunos e respectivas postagens.

#### 4.2 Processamento

Após a agregação, as sentenças são submetidas a uma API (*IBM Watson Language Translator*) para conversão do idioma antes de realizar a análise de emoções e sentimentos, visto que essa análise é feita apenas na língua inglesa. A API de AS, *IBM Watson Tone Analyzer*, utiliza a abordagem baseada em aprendizagem de máquina supervisionada, que implementa o algoritmo *Support Vector Machine*<sup>4</sup>. Assim como qualquer outro serviço de AS disponível no mercado, o funcionamento da API consiste basicamente em realizar: segmentação, tokenização, previsão de classes gramaticais, lematização, apontar as "stopwords", analisar as dependências, encontrar palavras sintaticamente relacionadas e realizar o reconhecimento de entidades nomeadas.

O resultado do processamento é a geração de arquivos no formato de planilha de dados (XLSX) com as colunas: código do aluno, nota avaliativa, identificação de cinco emoções básicas segundo Ekman (1992) (Tristeza, Alegria, Medo, Aversão e Raiva) por frase e polarização do sentimento (Positivo, Negativo e Neutro) para realização da análise e realização de cálculo de correlação.

### 5 RESULTADOS E DISCUSSÃO

A partir do seu SGA, a instituição educacional, foco da pesquisa, forneceu uma planilha com as notas das avaliações (em formato XLSX), bem como os *logs* da interação entre professor e alunos no AVA (Moodle), em formato não estruturado (DOCX). Após análises exploratórias do conteúdo das mensagens trocadas (*logs*)

<sup>2</sup> <https://gotit.ai/en-us/Home/Sentiment>

<sup>3</sup> <https://www.ibm.com/demos/live/naturalLanguage-understanding/self-service/home>

<sup>4</sup> [https://mediacenter.ibm.com/media/Support+Vector+Machine+%28SVM%29/0\\_vt4iyv5i](https://mediacenter.ibm.com/media/Support+Vector+Machine+%28SVM%29/0_vt4iyv5i)

e das notas, foram selecionados para estudo os dados das disciplinas Análise e Projeto de Software, oferecida no 1º e 2º semestres de 2019 por um mesmo professor. Dos 72 alunos da disciplina, apenas 49 possuíam notas de avaliação e que tivessem tido alguma interação durante o curso. Foram obtidas 1602 mensagens com nível de granularidade de sentença (LIU, 2015). Destas sentenças, 1347 (84,03%) puderam ser classificadas de acordo com a polaridade dos sentimentos (positivo, negativo ou neutro) e emoções predominantes (tristeza, alegria, medo, aversão e raiva).

Ao analisar todas as sentenças classificadas por meio da análise de sentimentos, observou-se que 60,43% eram neutras, 28,73% positivas e 10,84% negativas. Nas análises de emoções foram avaliadas as mensagens dos alunos e do professor utilizando como critério a média dos escores para cada emoção, destacando-se a emoção predominante.

Em uma primeira observação, o resultado da emoção predominante dos alunos como um todo foi a alegria (24,56%), seguida pela tristeza (20,92%), raiva (7,87%), medo (5,37%) e aversão (4,78%). Outra observação relevante foi a análise da emoção predominante nas mensagens do professor, nas quais também prevaleceu a alegria (24,63%), seguida por tristeza (18,03%), raiva (8,52%), aversão (6,23%) e medo (6,17%). Assim, a emoção predominante foi “alegria” tanto na análise da turma quanto do professor.

Segundo Cui e Gou (2019), as emoções positivas podem fazer com que os alunos se sintam satisfeitos e tenham grande confiança no aprendizado. Porém, de acordo com Wang, Hu e Zhou (2018), é importante também dar atenção às emoções negativas, pois estas podem indicar que o aluno está propenso a perder o interesse pelo curso. Além disso, essas emoções negativas podem provocar irritação nos alunos, fazendo com que percam o interesse pelo aprendizado. Tão importante quanto saber quais são os alunos com emoções positivas é conhecer aqueles com traços de tristeza e outras emoções negativas, a fim de evitar desempenho insatisfatório ou mesmo evasão.

Para verificar uma possível relação entre as emoções predominantes e o desempenho acadêmico, a classe foi dividida em dois grupos distintos: um formado por alunos com desempenho acima do esperado (Grupo A – rendimento superior ou igual a 70%), somando 40 estudantes (81,43% dos alunos), e outro (Grupo B) com desempenho abaixo do esperado (rendimento abaixo de 70%), totalizando nove estudantes (18,57% do total).

Considerando o estado emocional positivo predominante no professor e que parte significativa dos alunos (Grupo A) apresentou rendimento acima do esperado, pode-se conjecturar, ainda que fracamente, a existência de uma relação positiva entre essas duas situações. Ao analisar a predominância do estado emocional positivo “alegria”, com 25,54%, (frente 20,39% “de tristeza”) dos alunos do Grupo A e negativo “tristeza”, com 23,27%, (frente a 20,21% de “alegria”) dos alunos do Grupo B, pode-se supor que exista uma relação entre o estado emocional dos alunos e o desempenho acadêmico.

Após a análise de emoções e sentimentos foram realizados cinco ensaios estatísticos, baseados em Regressão Linear Múltipla, visando explorar outras variáveis que pudessem estar relacionadas com o rendimento acadêmico dos alunos. Assim, a variável dependente em todos os ensaios foi *Nota obtida*. Os resultados obtidos são apresentados nas Tabelas 1 (Estatística de regressão) e 2 (Significância).

Tabela 1 – Resultados obtidos (Estatística de regressão)

	Grupo B			Grupo A	
	Ensaio 1	Ensaio 2	Ensaio 3	Ensaio 4	Ensaio 5
<b>R múltiplo</b>	0,46	0,44	0,23	0,23	0,03
<b>R-Quadrado</b>	0,21	0,19	0,05	0,05	0,00
<b>R-quadrado ajustado</b>	-0,31	-0,33	-0,02	0,01	-0,03
<b>Erro padrão</b>	2,68	2,71	2,44	2,39	2,46
<b>Observações</b>	6	6	27	27	27

Fonte: os autores (2021)

Tabela 2 – Resultados obtidos (Significância)

	<b>Coefficientes</b>	<b>Erro padrão</b>	<b>Stat t</b>	<b>valor-P</b>	<b>95% inferiores</b>	<b>95% superiores</b>
<b>Ensaio 1 (Grupo B)</b>						
Interseção	5,00	5,14	0,97	0,40	-11,36	21,37
Total de palavras escritas	0,01	0,014	0,76	0,49	-0,03	0,05
Score da emoção "Tristeza"	7,48	11,14	0,67	0,55	-27,98	42,94
<b>Ensaio 2 (Grupo B)</b>						
Interseção	5,043	5,31	0,94	0,41	-11,86	21,95
Média de palavras escritas	0,24	0,34	0,72	0,52	-0,84	1,34
Score da emoção "Tristeza"	1,45	11,81	0,12	0,90	-36,13	39,05
<b>Ensaio 3 (Grupo A)</b>						
Interseção	20,35	2,41	8,43	1,21	15,37	25,33
Número de mensagens	-0,01	0,05	-0,17	0,86	-0,12	0,10
Score da emoção "Alegria"	-7,66	6,51	-1,17	0,25	-21,10	5,77
<b>Ensaio 4 (Grupo A)</b>						
Interseção	20,08	1,79	11,20	3,07	16,39	23,77
Score da emoção "Alegria"	-7,32	6,09	-1,20	0,24	-19,87	5,22
<b>Ensaio 5 (Grupo A)</b>						
Interseção	17,82	1,09	16,30	7,82	15,57	20,07
Número de mensagens	0,01	0,05	0,18	0,85	-0,10	0,12

Fonte: os autores (2021)

**Ensaio 1** (desempenho dos alunos do Grupo B). Nesse ensaio, foram utilizadas como variáveis independentes o *Score da emoção "Tristeza"* e o *Total de palavras escritas*. A partir das variáveis independentes obteve-se um R-quadrado ajustado de -0,31. Portanto, a explicação da *Nota obtida* por essas variáveis independentes, com seis observações, não resultou significância estatística.

**Ensaio 2** (desempenho dos alunos do Grupo B). Aqui, foram consideradas as variáveis independentes *Score da emoção "Tristeza"* e *Média de palavras escritas*. Observa-se que o modelo utilizando essas variáveis apresentou um R-quadrado ajustado de -0,33. A explicação da *Nota obtida* pelas variáveis independentes consideradas com 6 observações não resultou significância estatística.

**Ensaio 3** (desempenho dos alunos do Grupo A). Para o terceiro ensaio foram alterados os critérios de seleção de alunos e as variáveis preditoras. Foram considerados os alunos do Grupo A e as variáveis independentes *Score da emoção "Alegria"* e *Número de mensagens*. Observa-se que o modelo criado com essas variáveis independentes apresentou um R-quadrado ajustado de -0,02. Mais uma vez, a explicação da *Nota obtida* por essas variáveis, agora com 27 observações, não apresentou significância estatística.

**Ensaio 4** (desempenho dos alunos do Grupo A). Para o quarto ensaio foi utilizada somente a variável *Score da emoção "Alegria"*. Observa-se que o modelo com esta variável apresentou um R-quadrado ajustado de 0,01. Assim como nos ensaios anteriores não se observou correlação entre a variável independente (*Score da emoção "Alegria"*) e *Nota obtida*.

**Ensaio 5** (desempenho dos alunos do Grupo A). No último ensaio foi analisada a relação entre as variáveis *número de mensagens* e *nota obtida*. Observa-se que o modelo com estas variáveis apresentou um R-quadrado ajustado de -0,03, não evidenciando a existência de correlação entre as variáveis.

As significâncias obtidas em todos os modelos indicam que o modelo de regressão não é significativo. Contudo o objetivo de contribuir para elaboração de um modelo preditivo por meio da identificação da

existência de correlação entre as variáveis observadas foi atingindo, pois, a detecção das emoções dos alunos nas interações via texto pode se tornar relevante quando combinados com outras variáveis. É razoável supor que tais resultados se devam ao reduzido tamanho da amostra, o que pode ser contornado em estudos futuros.

#### 4 CONCLUSÃO

Analisando-se as porcentagens dos sentimentos dos alunos em extremos, pode-se notar a influência destes no sucesso acadêmico. Observou-se que a relação entre sentimento positivo e aprendizado, tanto por parte do tutor quanto por parte do aluno, pode influenciar o desempenho acadêmico do aluno. O mesmo pode ser observado com relação ao sentimento do tutor. Embora esse estudo não confirme essas relações de forma categórica, pode-se esperar que um modelo preditivo possa ser alcançado a partir de uma população maior.

Por fim, os resultados obtidos em relação a análise de sentimentos foram satisfatórios e suficientes para mostrar que a ferramenta proposta funcionaria bem em contextos reais de utilização. Contudo, como trabalhos futuros sugere-se repetir o estudo para uma amostra de dados maior, com a aplicação de novas técnicas de aprendizagem.

#### REFERÊNCIAS

- ANDRÉS, María L. A.; STELZER, Florencia; JURIC, Lorena C.; INTROZZI, Isabel; RODRIGUEZ-CARVAJAL, Raquel; GUZMÁN, Jossé I. N. Regulación Emocional y Desempeño Académico: revision sistemática de sus relaciones empíricas. **Psicologia em Estudo**, v. 22, n. 3, p. 299-311, 2017.  
<https://doi.org/10.4025/psicolestud.v22i3.34360>
- ARNOLD, Magda B. **Emotion and personality**. Vol. I. Psychological aspects. New York: Columbia University Press, 1960.
- BOBÓ, Míria; CAMPOS, Fernanda; STRÖELE, Victor; BRAGA, Regina; DAVID, José M. N. Análise de Sentimento na Educação: Um Mapeamento Sistemático da Literatura. CONGRESSO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (CBIE), 30., SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE). Brasília. **Anais [...]**. SBC: Brasília, 2019. p. 249-258. <https://doi.org/10.5753/cbie.sbie.2019.249>
- CIOŚ, Krzysztof J.; PEDRYCZ, Witold; SWINIARSKI, Roman W.; KURGAN, Lukasz A. **Data mining: a knowledge discovery approach**. Boston: Springer Science & Business Media, 2007, p. 9-24.
- CUI, Q.; GOU, J. Review of Online Learning Behavior Analysis. INTERNATIONAL CONFERENCE ON ECONOMY, JUDICATURE, ADMINISTRATION AND HUMANITARIAN PROJECTS (JAHP 2019), 4., **Proceedings [...]**. Kaifeng, China: Atlantis Press, 2019. p. 2352-5428.
- DOSCIATTI, Mariza M. **Um método para a identificação de emoções básicas em textos em português do Brasil usando máquinas de vetores de suporte em solução multiclasse**. 2015. 225 f. Tese (Doutorado) - Curso de Informática, Programa de Pós-Graduação em Informática, Pontifícia Universidade Católica do Paraná, Curitiba, 2015.
- EKMAN, Paul. An argument for basic emotions. **Cognition and Emotion**, v. 6, n. 3-4, p. 169-200, 2008.  
<https://doi.org/10.1080/02699939208411068>
- FENG, Shi; WANG, Yaqi; SONG, Kaisong; WANG, Daling; YU, Ge. Detecting Multiple Coexisting Emotions in Microblogs with Convolutional Neural Networks. **Cognitive Computation**, v. 10, n. 1, p. 136-155, 2017.  
<http://dx.doi.org/10.1007/s12559-017-9521-1>.

GHAZARIAN, Peter G.; KWON, Sung-Ho. The future of American education: Trends, strategies, & realities. **Philosophy of Education**, v. 56, p. 147-177, 2015.

GONÇALVES, Vinícius P.; COSTA, Eduardo P.; VALEJO, Alan; R. FILHO, Geraldo P.; JOHNSON, Thienne M.; PESSIN, Gustavo; UEYAMA, Jô. Enhancing intelligence in multimodal emotion assessments. **Applied Intelligence**, v. 46, n. 2, p. 470-486, 2016. <http://dx.doi.org/10.1007/s10489-016-0842-7>.

GRAY, Jeffrey A. **The neuropsychology of anxiety**: An enquiry into the functions of the septo-hippocampal system. Clarendon Press/Oxford University Press, 1982.

HADDI, Emma; LIU, Xiaohui; SHI, Yong. The Role of Text Pre-processing in Sentiment Analysis. **Procedia Computer Science**, v. 17, p. 26-32, 2013. <http://dx.doi.org/10.1016/j.procs.2013.05.005>

HECKMAN, James; KAUTZ, Tim. Fostering and Measuring Skills: interventions that improve character and cognition. **National Bureau of Economic Research**, v. 19656, n. 1, p. 1-122, 2013. <http://dx.doi.org/10.3386/w19656>.

IMANI, Maryam; MONTAZER, Gholam Ali. A survey of emotion recognition methods with emphasis on E-Learning environments. **Journal of Network and Computer Applications**, v. 147, p. 102423, 2019. <http://dx.doi.org/10.1016/j.jnca.2019.102423>

IZARD, Carroll E. **The face of emotion**. New York: Appleton-Century Crofts, 1971.

JAMES II, William. What is an Emotion? **Mind**, v. 9, n. 34, p. 188–205, 1884.

KAGAN, Jerome. Behavioral inhibition as a temperamental category. In: DAVIDSON, R. J.; SCHERER, K. R.; Goldsmith, H. H. (Eds.). **Handbook of affective sciences**. Series in Affective Science. New York: Oxford University Press. 2003, p. 320-331.

KAGKLIS, Vasileios; KARATRANTOU, Anthi; TANTOULA, Maria; PANAGIOTAKOPOULOS, Christos T.. A Learning Analytics Methodology for Detecting Sentiment in Student Fora: A Case Study in Distance Education. **European Journal of Open, Distance and e-Learning**, v. 18, n. 2, 2015.

LAZARUS, Richard S. **Emotion and adaptation**. New York: Oxford University Press, 1991.

LIBRALON, Giampaolo L. **Modelagem computacional para reconhecimento de emoções baseada na análise facial**. 2014. 196 f. Tese (Doutorado) – Programa de Pós-graduação em Ciências de Computação e Matemática Computacional, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2014. <https://doi.org/10.11606/T.55.2014.tde-10042015-104538>

LIPNEVICH, Anastasiya A.; ROBERTS, Richard D. Noncognitive skills in education: emerging research and applications in a variety of international contexts. **Learning And Individual Differences**, v. 22, n. 2, p. 173-177, 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.lindif.2011.11.016>

LIU, Bing. Sentiment Analysis and Subjectivity. In: INDURKHAYA, N.; DAMERAU, F. J. (eds.). **Handbook of Natural Language Processing**. 2. ed. CRC Press, 2010. p. 627-666.

LIU, Bing. Sentiment Analysis and Opinion Mining. **Synthesis Lectures On Human Language Technologies**, v. 5, n. 1, p. 1-167, 2012. <http://dx.doi.org/10.2200/s00416ed1v01y201204hlt016>.

LIU, Bing. **Opinions, Sentiment and Emotion in Text**: mining opinions, sentiments and emotions. New York: Cambridge University Press, 2015.

LO, Siaw Ling; CAMBRIA, Erik; CHIONG, Raymond; CORNFORTH, David. Multilingual sentiment analysis: from formal to informal and scarce resource languages. **Artificial Intelligence Review**, v. 48, n. 4, p. 499-527, 2016. <http://dx.doi.org/10.1007/s10462-016-9508-4>.

MARQUEZ, Carlos; ROMERO, Cristóbal; VENTURA, Sebastian. Predicting School Failure Using Data Mining. In INTERNATIONAL CONFERENCE ON EDUCATIONAL DATA MINING, 4. **Proceedings...** Eindhoven, The Netherlands, July 6-8, 2011, 2010.

McDOUGALL, William. **An Introduction to Social Psychology**. Boston: John W. Luce & Co., 1926.

MENDEZ, Ildelfonso. The effect of the intergenerational transmission of noncognitive skills on student performance. **Economics Of Education Review**, v. 46, p. 78-97, 2015. <http://dx.doi.org/10.1016/j.econedurev.2015.03.001>

MIGUEL, Fabiano K. Psicologia das emoções: uma proposta integrativa para compreender a expressão emocional. **Psico-USF**, v. 20, n. 1, p. 153-162, 2015.

MORAIS, Felipe de, SILVA, Juarez da, REIS, Helena, ISOTANI, Seiji, JAQUES, Patricia. Computação Afetiva aplicada à Educação: uma revisão sistemática das pesquisas publicadas no Brasil. CONGRESSO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (CBIE) / SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), **Anais...**, 2017. pp. 163-172. <http://dx.doi.org/10.5753/cbie.sbie.2017.163>

MOREIRA, Vanessa de S.; SIQUEIRA, Sean W.; ANDRADE, Leila; PIMENTEL, Mariano. Análise de Sentimentos: Comparando o uso de ferramentas e a análise humana. BRAZILIAN SYMPOSIUM ON INFORMATION SYSTEMS, 12. **Anais...**, Florianópolis, maio 17-20, 2016.

MOWRER, O. Hobart. **Learning theory and behavior**. New York: Wiley, 1960.

PANKSEPP, Jaak. **Affective neuroscience: The foundations of human and animal emotions**. Series in affective science. Oxford University Press. 1998,

PLUTCHIK, Robert. A general psychoevolutionary theory of emotion. In: PLUTCHIK, R. **Theories of emotion**. Academic Press, 1980. p. 3-33.

RIBEIRO, Ralph B. S.; CARVALHO, Leandro S. G. de; OLIVEIRA, Elaine H. T. de; OLIVEIRA, David B. F. de; PESSOA, Marcela S. P. Investigação Empírica sobre os Efeitos da Gamificação de um Juiz Online em uma Disciplina de Introdução à Programação. **Revista Brasileira de Informática na Educação**, v. 28, p. 461-490, 2020. <http://dx.doi.org/10.5753/rbie.2020.28.0.461>

ROBBINS, Stephen P. Emoções e Sentimentos. In: ROBBINS, Stephen P. **Comportamento Organizacional: teoria e prática no contexto brasileiro**. 14. ed. São Paulo: Pearson Prentice Hall, 2010. Cap. 4. p. 91-124.

RODRIGUEZ, Pilar; ORTIGOSA, Alvaro; CARRO, Rosa M. Extracting Emotions from Texts in E-Learning Environments, INTERNATIONAL CONFERENCE ON COMPLEX, INTELLIGENT, AND SOFTWARE INTENSIVE SYSTEMS. 6. **Proceedings...**, 2012, pp. 887-892, <http://dx.doi.org/10.1109/CISIS.2012.192>

RUSSELL, James A. A circumplex model of affect. **Journal Of Personality And Social Psychology**, v. 39, n. 6, p. 1161-1178, 1980. <http://dx.doi.org/10.1037/h0077714>

SONG, Ge ; YE, Yunming; DU; Xiaolin; HUANG, Xiaohui. Short Text Classification: a survey. **Journal Of Multimedia**, v. 9, n. 5, p. 635-643, 2014. <http://dx.doi.org/10.4304/jmm.9.5.635-643>

SUERO-MONTERO, Calkin; SUHONEN, Jarkko. Emotion analysis meets learning analytics: online learner profiling beyond numerical data. In: KOLI CALLING INTERNATIONAL CONFERENCE ON COMPUTING EDUCATION RESEARCH. 14. **Proceedings...** 2014. p. 165-169.

TAO, Jie; FANG, Xing. Toward multi-label sentiment analysis: a transfer learning-based approach. **Journal of Big Data**, v. 7, n. 1, p. 1-26, 2020. <http://dx.doi.org/10.1186/s40537-019-0278-0>

WANG, Ling; HU, Gongliang; ZHOU, Tiehua. Semantic analysis of learners' emotional tendencies on online MOOC education. **Sustainability**, v. 10, n. 6, 1921, 2018. <http://dx.doi.org/10.3390/su10061921>

WATSON, John B. **Behaviorism**. Chicago: University of Chicago Pres, 1930.

WEINER, Bernard; GRAHAM, Sandra. An attributional approach to emotional development. In: IZARD, C.; KAGAN, J.; ZAJONC, R. (Eds.), **Emotion, cognition and behavior**. Cambridge, MA: Cambridge University Press, 1984. pp. 167-191.