

## **Uso de Aprendizado de Máquina em Fóruns de Ambientes Virtuais de Aprendizagem: Uma Revisão Sistemática de Literatura**

Francisco Romes da Silva Filho, UFC, romesfilho\_cc@alu.ufc.br, 0000-0002-4187-9774  
Rafael Augusto Ferreira do Carmo, UFC, carmorafael@virtual.ufc.br, 0000-0002-5080-1688  
Gabriel Antoine Louis Paillard, UFC, gabriel@virtual.ufc.br, 0000-0003-3608-2637  
Ernesto Trajano de Lima, UFC, ernesto@virtual.ufc.br, 0000-0002-0959-7689

**Resumo:** Fóruns desempenham um papel central nos Ambientes Virtuais de Aprendizagem (AVAs), fornecendo uma forma simples e valiosa de comunicação assíncrona entre os partícipes de cursos do ensino superior. O Aprendizado de Máquina (AM) tem se destacado como uma ferramenta essencial para a análise de fóruns, oferecendo a capacidade de fazer previsões, identificar padrões e gerar visualizações de dados. Este artigo apresenta uma revisão sistemática da literatura cujo objetivo é identificar as principais características das soluções baseadas em AM que utilizam os fóruns dos AVAs como objeto de aprendizagem para os modelos.

**Palavras-chave:** fórum, ead, aprendizagem de máquina, rsl, ensino superior.

## **Use of Machine Learning in Virtual Learning Environment Forums: A Systematic Literature Review**

**Abstract:** Forums serve as central elements in Virtual Learning Environments (VLEs), providing a simple and valuable means of asynchronous communication amongst participants in higher education. Machine Learning (ML) has emerged as a key component for forum analysis, offering the capability to make predictions, identify patterns, and generate data visualizations. This paper presents a systematic literature review aiming to identify the main characteristics of ML-based solutions that utilize VLE forums as the objects of learning for models.

**Keywords:** forum, distance learning, machine learning, slr, higher education.

### **1. Introdução**

Ambientes Virtuais de Aprendizagem (AVAs) são plataformas educacionais que estendem o processo de aprendizagem para além dos muros dos locais de formação, empregando para este fim diversos recursos em múltiplos formatos, tais como: vídeos, lições interativas, questionários, avaliações regulares, documentos digitais, fóruns, entre outros. O cerne deste trabalho está no uso dos fóruns que são ambientes onde os alunos tratam os tópicos relacionados às suas disciplinas a qualquer momento e lugar. Esta ferramenta assíncrona possibilita uma interação permanente entre os membros constituintes da formação proposta, o que potencializa a aprendizagem e fixação do conteúdo apresentado, seja através de atividades colaborativas ou discussões sobre determinado tema(Wei e Jia, 2021; Borges; Nogueira e Barbosa, 2016).

Um AVA pode gerar uma diversidade de dados de forma contínua o que possibilita a aplicação de atividades de análise e monitoramento para a extração de informações. O Aprendizado de Máquina (AM) é uma das áreas da inteligência artificial que emprega modelos formais com o uso de algoritmos capazes de extrair conhecimento a partir de um conjunto de dados de entrada. Desta forma, o uso de AM possibilita a aplicação de modelos preditivos e descritivos como, por exemplo, sobre o conjunto de interações do corpo discente e assim buscar padrões que categorizem determinado comportamento associado ao seu desempenho no curso, o que possibilita a proposição de adequações

para melhoria do processo de aprendizagem (Papamitsiou e Economides, 2014; Raschka e Mirjalili, 2019).

Este artigo propõe uma Revisão Sistemática de Literatura (RSL) para identificar as principais características das soluções propostas com AM que utilizam fóruns de AVAs como objeto de aprendizagem para os modelos. O uso de um protocolo amplamente difundido como o RSL nos dá as garantias necessárias para assegurar a confiabilidade na avaliação e interpretação dos estudos relevantes sobre uma questão de pesquisa específica, tópico ou fenômeno de interesse (Kitchenham e Charters, 2007).

Outros estudos fazem o levantamento do estado de arte por meio de uma RSL, incluindo Wei e Jia (2021) que o faz do ponto de vista global do uso da área da inteligência artificial em AVAs; Papamitsiou e Economides (2014) que destaca as evidências do uso prático de mineração de dados educacional; Loncar, Barrett e Liu (2014) o faz observando especificamente as tendências do uso de fóruns de discussão, sem abordar com foco em AM; já Tamada, Netto e Lima (2019) o faz visando analisar especificamente a predição e redução de evasão com AM dos estudantes que fazem uso de AVAs. A presente RSL é diferente das demais por observar especificamente estudos que propõem o uso de AM e que obrigatoriamente usam o fórum de discussão de AVAs (de educação superior) como objeto de aprendizado dos modelos.

## **1.1. Protocolo da Revisão**

### **1.1.1. Questões de Pesquisa**

As questões de pesquisas deste trabalho foram construídas através da estratégia PICOC (População, Intervenção, Comparação, Resultados e Contexto), com a qual foi possível elaborar as questões de pesquisa e estruturar o processo de busca. A população é de onde a evidência é coletada; a intervenção específica a intervenção aplicada no estudo empírico; a comparação para a qual a intervenção é comparada; os resultados refere-se aos resultados dos experimentos; e o contexto do estudo define-se como uma visão ampliada da população, incluindo se é conduzido em academia ou indústria (Wohlin *et al.*, 2012; Siksnelyte-Butkiene *et al.*, 2021). Através dela, fóruns de AVAs de educação à distância foram definidos como **População**; uso de AM como **Intervenção**; visão geral das soluções de AM propostas para fóruns de AVA para EAD como **Resultado**; e AVAs utilizados em instituições educacionais de ensino superior como **Contexto**. Não se tem o objetivo de avaliar o uso de outras ferramentas de IA pois o emprego de AM em fóruns é o foco deste trabalho e portanto não há **comparações** neste aspecto.

Logo, no cenário da EAD pergunta-se: **(1)** Quais são as principais aplicações ou tarefas em que o aprendizado de máquina é utilizado nos fóruns de AVAs? **(2)** Quais algoritmos de Aprendizado de Máquina são comumente adotados na análise de fóruns em AVAs? **(3)** Quais são as características dos dados mais presentes em soluções que utilizam aprendizado de máquina nos fóruns de AVAs? **(4)** Quais procedimentos de pré-processamento mais adotados para tratar os dados dos fóruns de AVAs? **(5)** Quais as estratégias de engenharia de atributos são adotadas para os dados dos fóruns de AVAs? **(6)** Quais métricas de avaliação são utilizadas em fóruns de AVAs? **(7)** Como as soluções que empregam aprendizado de máquina impactam a experiência dos usuários nos fóruns de AVAs?

### **1.1.2. Estratégias de Busca e de Seleção de Estudos**

A Figura 1, apresenta o processo de busca desta RSL. Para o primeiro passo de busca, utilizou-se a definição gerada pela estratégia PICOC para a definição das *strings* de

busca utilizadas. Para cada elemento da PICOC, definiu-se uma palavra-chave e diversos sinônimos que foram conectados através do conector lógico OR (ou) e cada conjunto palavra-chave/sinônimo foi conectado pelo conector lógico AND (e), ou seja, para que um trabalho fosse inicialmente selecionado ele deveria possuir em seu texto todos os elementos da PICOC, seja na forma das palavras-chave ou de seus sinônimos.

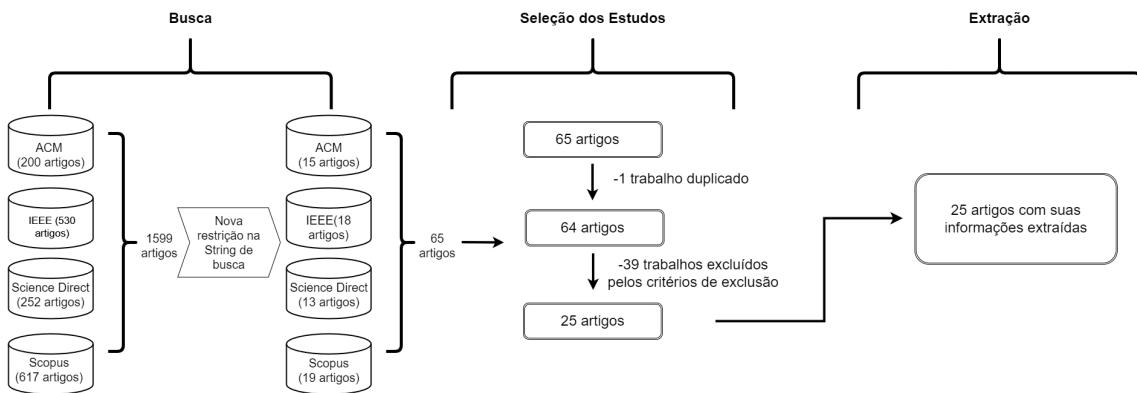


Figura 1. Resumo das Etapas da Revisão Sistemática de Literatura

Assim, a *string* de busca base para a revisão foi: (**“Distance Education”** OR **“Distance Learning”** OR **“E-learning”** OR **“Electronic Learning”** OR **“Online Class”** OR **“Online Course”**) AND (**“Virtual Learning Environment”** OR **“Learning Management Systems”** OR **“VLE”** OR **“LMS”**) AND (**“Machine Learning”** OR **“Data Mining”** OR **“Data Science”** OR **“Deep Learning”** OR **“Natural Language Processing”**) AND (**“forum”** OR **“asynchronous discussion”** OR **“online discussion”**). As bases de dados utilizadas foram a *ACM Digital Library*, a *IEEE Explore*, a *Science Direct* e a *Scopus*.

A aplicação “crua” desta *string* de busca retornou 1599 trabalhos. Após análise de um subconjunto destes trabalhos, percebeu-se que a busca resultava em trabalhos relacionados a MOOCs (Ruipérez-Valiente *et al.*, 2021; Crossley *et al.*, 2016; Doleck; Lemay e Brinton, 2021), fóruns online, redes sociais, eventos, etc., dada a onipresença do termo fórum nestes mais diversos cenários. Como fóruns em uma escala mais global não são foco deste estudo, tal qual discutido na Seção 4, decidiu-se por restringir a busca aos trabalhos que mencionam o termo “fórum” e seus sinônimos em seu resumo (ou *abstract*). Essa restrição foi adaptada para cada base de dados, observando as limitações de cada base e a consistência da metodologia. Após esse ajuste, verificou-se a consistência temática dos trabalhos retornados, portanto se prosseguiu com a execução da pesquisa com essa condição específica.

Definiram-se como critérios de inclusão: (1) Estudos primários completos publicados a partir de 2012; (2) Estudos publicados em conferência ou periódico; e (3) Estudos que apresentem soluções utilizando AM em fóruns de AVAs de educação à distância. Já os critérios de exclusão são: (1) Estudos que não respondam a nenhuma das questões de pesquisa; (2) Estudos secundários; (3) Estudos que não utilizam AM ou fórum em sua solução proposta; (4) Estudos duplicados; (5) Estudos curtos (até 5 páginas); e (6) Estudos publicados antes de 2012. Utilizou-se a ferramenta Parsifal \*para a implementação dos principais passos do protocolo da RSL.

\* <https://parsif.al/>

## 2. Resultados da Revisão

Com a execução do protocolo da RSL, foram capturados 65 trabalhos, sendo 25 aceitos e 40 rejeitados a partir dos critérios de seleção apresentados. Dos estudos selecionados e analisados por completo, 2 foram publicados em 2012, 3 em 2013 e mais 2 em 2014, 2 em 2015, nenhum em 2016, 2, 4 e 1 em 2017, 2018 e 2019, respectivamente, 1, 2, 4, e 4 em 2020, 2021, 2022 e 2023.

A Tabela 1 mostra a estratificação dos estudos por tarefa de AM, tipos de algoritmos, métricas e tipos de dados utilizados nos estudos. Para a identificação dos estudos foi utilizado um identificador único da seguinte forma: (E1) (Sha *et al.*, 2022b); (E2) (Distante *et al.*, 2014); (E3) (Cerulo e Distante, 2013); (E4) (Maina; Oboko e Waiganjo, 2017); (E5) (Pong-inwong e Rungworawut, 2012); (E6) (Husni; Jumaat e Tasir, 2022); (E7) (Borges; Nogueira e Barbosa, 2016); (E8) (Murad *et al.*, 2018); (E9) (Sha *et al.*, 2022a); (E10) (Sheshadri *et al.*, 2018); (E11) (López; Redondo e Vilas, 2021); (E12) (Valsamidis *et al.*, 2012); (E13) (Gkонтzis *et al.*, 2017); (E14) (Saleh; Iriarte e Chang, 2022); (E15) (Olivé *et al.*, 2018); (E16) (Romero *et al.*, 2013); (E17) (Bosch *et al.*, 2018); (E18) (Norz *et al.*, 2023); (E19) (Alachiotis; Stavropoulos e Verykios, 2019); (E20) (Tobarra *et al.*, 2014); (E21) (Erlin; Rio e Rahmiati, 2013); (E22) (Kovanović *et al.*, 2015), (E23) (Neto *et al.*, 2021); (E24) (Barbosa *et al.*, 2021); e (E25) (Barbosa *et al.*, 2020). A seguir, as evidências encontradas e, consequentemente, as respostas para as questões de pesquisas são apresentadas.

Trabalho	Tarefa de AM	Algoritmos	Métricas	Dados	Trabalho	Tarefa de AM	Algoritmos	Métricas	Dados
E1	Classificação	Probabilísticos Baseados em Árvore Redes Neurais	Acurácia Kappa AUC F1 score	Texto Metadados	E2	Modelagem de Tópicos	Latent Dirichlet Allocation	-	Texto
E3	Modelagem de Tópicos	Latent Dirichlet Allocation	Acurácia	Texto	E4	Clusterização	Particionais Probabilísticos	-	Logs
E5	Classificação	Probabilísticos Baseados em Árvore	Acurácia	Texto	E6	Classificação	Baseados em Árvore	-	Texto
E7	-	-	-	Metadados	E8	Classificação	Baseados em Árvore	-	Texto
E9	Classificação	Probabilísticos Baseados em Árvore Redes Neurais Margem Máxima	H-Bias AUC ABROCA Distribuição de viés	Texto Metadados Logs	E10	Classificação	Probabilísticos Baseados em Árvore Baseados em Instância	F1 score	Texto Metadados Logs
E11	Classificação	Probabilísticos	Precisão Revocação F1 score	Texto	E12	Clusterização	Particionais Baseados em Grafos	-	Logs
E13	Classificação	Probabilísticos	-	Texto	E14	Sumarização	N-gram PoS Identifier	-	Texto
E15	Classificação	Probabilísticos Redes Neurais	Acurácia Precisão Revocação MCC	Metadados Logs	E16	Classificação Clusterização Regras de Associação	Probabilísticos Baseados em Árvore Redes Neurais Particionais Hierárquicos Redução de Dimensionalidade	Acurácia F1 Score	Logs
E17	Classificação	Probabilísticos	MCC Kappa	Metadados Logs	E18	Régressão	Régressão Linear Múltipla	CFI RMSEA Kappa	Logs
E19	Regressão	Regressão Linear Múltipla	ANOVA, $R^2$ Múltiplo $R^2$ $R^2$ ajustado Erro padrão	Logs	E20	Modelagem de Tópicos	Propõe Algoritmos	-	Metadados
E21	Classificação	Margem Máxima	Precisão, Revocação F1 score e erros	Texto	E22	Clusterização	Hierárquicos	MANOVA, ANOVA e DFA	Logs e Texto
E23	Classificação	Baseados em Árvore	Acurácia e Kappa	Texto	E24	Classificação	Baseados em Árvore	Acurácia e Kappa	Texto
E25	Classificação	Baseados em Árvore	Acurácia e Kappa	Texto					

Tabela 1. Estratificação dos artigos em Tarefa, Algoritmos, Métricas e Dados

### Quais são as principais aplicações ou tarefas em que o aprendizado de máquina é utilizado nos fóruns de AVAs?

Dos 25 estudos analisados nessa RSL, 15 utilizam AM para a tarefa de classificação de dados. Sha *et al.* (2022a), Olivé *et al.* (2018), Sheshadri *et al.* (2018), Romero *et al.* (2013) utilizam a classificação para prever a situação final do aluno, ou seja, se o aluno será aprovado ou não em uma disciplina ao fim do período letivo. Alachiotis, Stavropoulos e Verykios (2019) usa a tarefa de regressão para a predição do

valor numérico da nota final do aluno.

Outros estudos que aplicam a classificação têm o objetivo de classificar o tipo de conteúdo que está presente nas mensagens que foram postadas no fórum do AVA. Pong-inwong e Rungworawut (2012) e Gkонтzis *et al.* (2017) tentam identificar emoções e sentimentos presentes nas mensagens do fórum. Pong-inwong e Rungworawut (2012) classifica os comentários sobre o ensino do professor, em positivo ou negativo. Já Gkонтzis *et al.* (2017) classifica se as mensagens apresentam raiva, nojo, medo, alegria, tristeza ou surpresa e ainda observa a polaridade da mensagem (Negativo, Neutro e Positivo) com análise de sentimentos. Neto *et al.* (2021), Barbosa *et al.* (2021), Barbosa *et al.* (2020) classifica as mensagens com base no conceito de comunidade de inquirição (COI) – que visa descrever os elementos essenciais das interações sociais e construção de conhecimento em ambientes de educação online e híbrida e o faz mediante três dimensões para analisar essas interações: presença cognitiva, presença social e presença de ensino.

Outros fazem uso para melhorar a identificação das mensagens para os usuários. É o caso de López, Redondo e Vilas (2021) que utilizou classificação para identificar o conteúdo das mensagens, categorizando em conteúdo, código (linguagem de programação) e um terceiro que não seja os outros dois citados. Sha *et al.* (2022b) construiu classificadores binários para identificar o tipo da mensagem postada no fórum nas categorias urgência, confusão, sentimento, opinião, pergunta e resposta e ainda aplicou uma classificação do tipo multi-rótulo que identifica a aparição concorrente de diferentes categorias em um *post*. Sha *et al.* (2022a) categoriza as mensagens postadas em relevantes ou irrelevantes, destacando mensagens que possam ser mais valiosas aos usuários.

Outra aplicação, é a classificação de usuários dos AVA em grupos que os caracterizem. Husni, Jumaat e Tasir (2022) procura classificar o nível de aprendizagem (alta, baixa/média e irrelevante) dos estudantes através das mensagens e Bosch *et al.* (2018) procura identificar por meio de metadados e *logs* a qual dos grupos social o estudante faz parte, de forma similar, Kovanović *et al.* (2015) agrupa os estudantes baseados em suas atividades no AVA e relaciona com os conceitos de COI.

O aprendizado não supervisionado se faz presente também nos estudos analisados, destacando a importância dos modelos descritivos que descrevem e descobrem padrões nos dados, com a aplicação de técnicas de clusterização, regras de associação, sumarização e modelagem de tópicos. Maina, Oboko e Waiganjo (2017) constrói *clusters* visando agrupar o nível de participação dos alunos, Valsamidis *et al.* (2012) agrupa as atividades dos alunos dentro do AVA e identifica padrões para cada curso. Já Romero *et al.* (2013) aposta na clusterização como forma de realizar classificação dos alunos que serão aprovados e reprovados. (Saleh; Iriarte e Chang, 2022) e Tobarra *et al.* (2014) aplicam a tarefa de sumarização para resumir os *posts* presentes nos fóruns. O uso de modelagem de tópicos apresentou-se quando há o intuito de evoluir a visualização de informações, como a organização visual das mensagens postadas em um fórum (Cerulo e Distante, 2013; Distante *et al.*, 2014).

### **Quais algoritmos de Aprendizado de Máquina são comumente adotados na análise de fóruns em AVAs?**

Vários estudos empregam múltiplas técnicas na solução, então, é natural que algoritmos estejam listados repetidamente. Algoritmos probabilísticos são os mais utilizados, tendo o *Naïve Bayes* sido utilizado 5 vezes e a regressão logística, 3 (Sha *et al.*, 2022b; Pong-inwong e Rungworawut, 2012; López; Redondo e Vilas, 2021; Gkонтzis *et al.*, 2017; Romero *et al.*, 2013; Olivé *et al.*, 2018; Bosch *et al.*, 2018; Sheshadri *et al.*,

2018).

Os algoritmos baseados em árvores também foram comumente utilizados (Sha *et al.*, 2022a; Sha *et al.*, 2022b; Pong-inwong e Rungworawut, 2012; Husni; Jumaat e Tasir, 2022; Murad *et al.*, 2018; Sheshadri *et al.*, 2018; Romero *et al.*, 2013; Neto *et al.*, 2021; Barbosa *et al.*, 2020; Barbosa *et al.*, 2021). Ambas classes são capazes de identificar os atributos mais importantes dos dados (seja por importância do atributo, coeficientes e probabilidade logarítmica empírica) e, consequentemente, selecionar o subconjunto de dados que otimizam o desempenho do modelo. Então, entende-se que é possível indicar os aspectos mais importantes presentes nos dados, para tomada de decisão em uma possível intervenção em um AVA (Romero *et al.*, 2013; Sheshadri *et al.*, 2018; Pong-inwong e Rungworawut, 2012).

O domínio da educação demanda por soluções explicáveis e interpretáveis. Contudo, os algoritmos baseados em redes neurais profundas, classe conhecida por modelos que desempenham bem, entretanto possuem baixa transparência e interpretabilidade de seus resultados, também estão presentes nos estudos analisados. Neles, foi encontrada a presença de redes na arquitetura *Feed forward Neural Network*, *Multi Layer Perceptron*, *Long Short-Term Memory*, *Bi-directional Long Short-Term Memory* e redes neurais convolucionais (Sha *et al.*, 2022b; Sha *et al.*, 2022a; Olivé *et al.*, 2018; Romero *et al.*, 2013).

Para as tarefas, com menos menções, observou-se o uso de regressão linear múltipla para a análise de redes sociais (Alachiotis; Stavropoulos e Verykios, 2019; Norz *et al.*, 2023). Também verificou-se o uso de vários algoritmos de clusterização como *SimpleKmeans*, *Expectation Maximization*, *Markov Clustering Algorithm*, cluster hierárquico, *Xmeans*, *sequential Information Bottleneck* e *Farthest-first cluster* (Maina; Oboko e Waiganjo, 2017; Valsamidis *et al.*, 2012; Romero *et al.*, 2013; Kovanović *et al.*, 2015). Na modelagem de tópicos, o algoritmo que se destaca é o *Latent Dirichlet allocation* (Cerulo e Distante, 2013; Distante *et al.*, 2014). Na sumarização, observa-se o uso de *n-gram* e *part of speech identifier*, para determinação de elementos em textos (Saleh; Iriarte e Chang, 2022).

### **Quais são as características dos dados mais presentes em soluções que utilizam aprendizado de máquina nos fóruns de AVAs?**

Os trabalhos resgatados pelo processo da presente RSL utilizam dados de fóruns de AVAs, porém, em alguns casos o fazem combinando esses dados com outros. É notável, através da análise dos trabalhos, que os conjuntos de dados extraídos dos AVAs são divididos em 3 grupos característicos. É possível identificar um maior uso de mensagens de texto (dados não estruturados) postadas nos fóruns como objeto de aprendizado dos modelos preditivos e descritivos propostos nos estudos (Sha *et al.*, 2022b; Cerulo e Distante, 2013; Pong-inwong e Rungworawut, 2012; Sha *et al.*, 2022a; López; Redondo e Vilas, 2021; Gkонтзис *et al.*, 2017; Distante *et al.*, 2014; Husni; Jumaat e Tasir, 2022; Murad *et al.*, 2018; Saleh; Iriarte e Chang, 2022; Tobarra *et al.*, 2014; Kovanović *et al.*, 2015; Barbosa *et al.*, 2020; Barbosa *et al.*, 2021; Neto *et al.*, 2021; Erlin; Rio e Rahmiati, 2013).

Também bastante valorizados são os *logs* (dados estruturados) que registram atividades dos usuários desde o uso dos fóruns, a novas seções de *login*, tempo gasto em páginas de submissão de atividades e entre outros, ou seja, registram eventos relevantes no sistema, principalmente, de forma cronológica (Borges; Nogueira e Barbosa, 2016; Sha *et al.*, 2022a; Olivé *et al.*, 2018; Bosch *et al.*, 2018; Alachiotis; Stavropoulos e Verykios, 2019; Maina; Oboko e Waiganjo, 2017; Sheshadri *et al.*, 2018; Valsamidis *et al.*, 2012;

Norz *et al.*, 2023; Romero *et al.*, 2013; Kovanović *et al.*, 2015).

A terceira característica dos conjuntos de dados utilizados nesses problemas tratados por esses estudos são os metadados (dados estruturados e semiestruturados) dos cursos, estudantes, atividades, etc. que trazem mais clareza no uso dos elementos de um AVA no processo de aprendizagem, mas que precisam de uma etapa de pré-processamento (Sha *et al.*, 2022b; Borges; Nogueira e Barbosa, 2016; Sha *et al.*, 2022a; Olivé *et al.*, 2018; Bosch *et al.*, 2018; Sheshadri *et al.*, 2018).

### **Quais procedimentos de pré-processamento mais adotados para tratar os dados dos fóruns de AVAs?**

Os procedimentos de pré-processamento identificados estão alinhados ao tipo de dados utilizados e de tarefa aplicada pelos estudos. Assim, os procedimentos aplicados são consequência das características apresentadas pelos dados. Quando os dados a serem processados são do tipo não estruturados, como texto, os procedimentos mais comumente usados são a remoção de caracteres inválidos, remoção das *stopwords*, aplicação de *stemming* e para tornar os dados interpretáveis aos modelos utiliza-se de técnicas de codificação como: *Bag of Words*; TF-IDF; *BERT*; *Word2Vec*; *Doc2Vec*; *N-gram* e *part of speech identifier (POS identifier)* (Sha *et al.*, 2022b; Cerulo e Distante, 2013; Sha *et al.*, 2022a; López; Redondo e Vilas, 2021; Gkонтzis *et al.*, 2017; Distante *et al.*, 2014; Murad *et al.*, 2018; Barbosa *et al.*, 2020; Barbosa *et al.*, 2021; Neto *et al.*, 2021; Erlin; Rio e Rahmiati, 2013).

No tratamento de dados estruturados e semiestruturados o comum é realizar filtragem de dados faltantes, reduções de ruídos, remoção de inconsistências nos dados e transformações nos dados, para otimizar a leitura dos dados pelos modelos (Maina; Oboko e Waiganjo, 2017; Sheshadri *et al.*, 2018; Tobarra *et al.*, 2014; Borges; Nogueira e Barbosa, 2016; Valsamidis *et al.*, 2012; Norz *et al.*, 2023; Romero *et al.*, 2013; Kovanović *et al.*, 2015). Ainda é comum a remoção de dados e atributos justificada pela avaliação estatística dos dados (Bosch *et al.*, 2018; Alachiotis; Stavropoulos e Verykios, 2019). Outro importante processo utilizado é a normalização dos dados para uso de uma escala comum, sem distorcer as diferenças nas faixas de valores ou perder informações (Bosch *et al.*, 2018).

Outro conjunto de procedimentos que podem ser utilizados para melhorar a qualidade dos dados, tanto estruturados quanto não estruturados, para o aprendizado dos modelos é o uso de técnicas de balanceamentos (técnicas de *undersampling*, *oversampling* e híbridas) que procuram melhorar a qualidade do aprendizado do modelo modificando a quantidade de amostras dos dados com base na necessidade (Neto *et al.*, 2021; Barbosa *et al.*, 2020; Sha *et al.*, 2022a).

### **Quais as estratégias de engenharia de atributos são adotadas para os dados dos fóruns de AVAs?**

Quando se fala em estratégias de engenharia de atributos refere-se às otimizações nos atributos e nos seus dados para que o modelo obtenha um melhor desempenho ao consultar os dados originais. Portanto, abordagens como redução de dimensionalidade dos dados, seleção de subconjuntos dos dados ou codificação dos dados são práticas eficazes de engenharia de atributos para otimização dos modelos.

Para dados não estruturados a estratégia mais presente é a da utilização de codificação dos dados – como *Bag of Words*; TF-IDF; *BERT*; *Word2Vec*; *Doc2Vec*; *N-gram* e *part of speech identifier (POS identifier)* – pois, por exemplo, em sua maioria esses métodos de codificação transforma os dados em representações matriciais

interpretáveis pelos modelos e até algumas técnicas, como o *BERT* para sentenças, conseguem reduzir a dimensionalidade dos dados comparado a outras técnicas (Sha *et al.*, 2022b; Cerulo e Distante, 2013; Sha *et al.*, 2022a; López; Redondo e Vilas, 2021; Gkонтzis *et al.*, 2017; Distante *et al.*, 2014; Murad *et al.*, 2018; Erlin; Rio e Rahmiati, 2013; Barbosa *et al.*, 2020; Barbosa *et al.*, 2021; Neto *et al.*, 2021).

Para dados estruturados e semiestruturados como *logs* e metadados existem algumas abordagens, como seleção de um subconjunto de atributos dos dados por meio de avaliação de especialistas ou aplicação de algoritmos de seleção como *Select K Best*, *CfsSubsetEval*, *ChiSquaredAttributeEval*, *ConsistencySubset-Eval*, *SignificanceAttributeEval*, *SymmetricalUncertAttributeEval*, *GainRatio-AttributeEval*, *OneRAttributeEval*, *ReliefFAttributeEval* e *SVMAtributeEval* (Sha *et al.*, 2022b; Borges; Nogueira e Barbosa, 2016; Pong-inwong e Rungworawut, 2012; Romero *et al.*, 2013).

Outra opção viável para lidar com dados estruturados e semiestruturados é a construção de novos indicadores a partir dos dados existentes, a combinação de diferentes atributos para revelar uma nova informação demonstra-se uma prática frequente (por exemplo, através de uso de equações com os valores dos atributos) (Borges; Nogueira e Barbosa, 2016; Olivé *et al.*, 2018; Bosch *et al.*, 2018; Maina; Oboko e Waiganjo, 2017; Valsamidis *et al.*, 2012; Norz *et al.*, 2023; Kovanović *et al.*, 2015). Além disso, outros trabalhos optam por aplicar validações estatísticas nos atributos e selecionar a partir das evidências encontradas, por exemplo, técnicas como normalização, aplicação do coeficiente de correlação de *Kendall* e o teste de *Wilcoxon* (Bosch *et al.*, 2018; Alachiotis; Stavropoulos e Verykios, 2019; Sheshadri *et al.*, 2018; Romero *et al.*, 2013).

### **Quais métricas de avaliação são utilizadas em fóruns de AVAs?**

As métricas para avaliar o desempenho da tarefa de classificação apresentaram maior incidência. Resumidamente, as métricas de classificação têm o objetivo de avaliar a quantidade de acertos do modelo para identificar as classes corretamente. Por exemplo, acurácia, *kappa*, precisão e *f1 score* (Sha *et al.*, 2022b; López; Redondo e Vilas, 2021; Barbosa *et al.*, 2020; Neto *et al.*, 2021; Barbosa *et al.*, 2021). Na regressão, as métricas quantificam o desempenho do modelo em prever valores numéricos, representando a diferença entre o valor previsto e o valor real (Alachiotis; Stavropoulos e Verykios, 2019). Para avaliação de *clusters*, quanto mais uma instância está próxima de outra, representando que a instância está adequadamente agrupada (Romero *et al.*, 2013; Maina; Oboko e Waiganjo, 2017).

É importante destacar também que alguns estudos não apresentam os resultados dos modelos por meio de métricas, apenas o fazem mediante discussão de impacto no contexto do AVA, o que revela um interesse maior no uso dessas soluções como forma de automatizar tarefas e assim ofertar mais informações para discussão de eventuais intervenções. Entretanto, isso dificulta a comparação com estudos semelhantes e o entendimento do desempenho do ponto de vista computacional (Borges; Nogueira e Barbosa, 2016; Gkонтzis *et al.*, 2017; Maina; Oboko e Waiganjo, 2017; Husni; Jumaat e Tasir, 2022; Valsamidis *et al.*, 2012; Saleh; Iriarte e Chang, 2022).

### **Como as soluções que empregam aprendizado de máquina impactam a experiência dos usuários nos fóruns de AVAs de educação à distância?**

Como contribuição comum de todos os estudos analisados, observa-se que com o uso de AM utilizando dados de fóruns e de outras instâncias dos AVAs, se possibilita que tutores, professores e gestores tomem decisões e ações baseadas em descobertas feitas pelas soluções propostas. Além dos resultados oferecidos pelos modelos de AM, é

possível realizar análises sobre os fatores que impactam nas descobertas desses modelos. Isso demonstra que o AM não apenas fornece resultados precisos na identificação de fenômenos, mas também oferece descrições interpretáveis desses fenômenos (Olivé *et al.*, 2018; Sha *et al.*, 2022b; Alachiotis; Stavropoulos e Verykios, 2019).

O uso de soluções de AM aplicadas a problemas presentes em AVAs possibilita a predição precoce do desempenho em uma disciplina, o que oferece ao professor mais viabilidade de intervir na aprendizagem dos alunos (Sheshadri *et al.*, 2018; Olivé *et al.*, 2018; Alachiotis; Stavropoulos e Verykios, 2019; Romero *et al.*, 2013; Sha *et al.*, 2022a).

Aliado de forma direta e indireta ao desempenho, o conteúdo produzido pelos alunos no fórum e nos demais elementos do AVA, podem trazer diferentes descobertas para os interessados, por exemplo: avaliar os comentários referentes a didática de um professor, como um aluno apresenta seu conhecimento, como são as atividades no AVA do aluno e emoções em mensagens postadas (Pong-inwong e Rungworawut, 2012; Gkонтzis *et al.*, 2017; Maina; Oboko e Waiganjo, 2017; Valsamidis *et al.*, 2012; Neto *et al.*, 2021; Kovanović *et al.*, 2015; Barbosa *et al.*, 2020; Barbosa *et al.*, 2021).

Com as previsões de alerta geradas por soluções que fazem uso do AM, os instrutores podem ajustar seu processo de ensino ou adotar abordagens de ensino adaptáveis para atender às necessidades dos alunos com baixo desempenho de aprendizado à medida que o curso avança. Um exemplo é (Maina; Oboko e Waiganjo, 2017) que a partir da obtenção dos *clusters* a partir do nível de participação dos usuários, é realizada a construção de grupos de estudos, de forma automática, para que os estudantes de diferentes níveis se auxiliem.

### 3. Discussão

Observa-se, por meio dos estudos analisados, o quanto a área da educação pode optar por soluções de AM que sejam mais interpretáveis, transparentes e que permitam um maior espaço para discussão. Nota-se que alguns estudos dispensam o uso de métricas para avaliar o desempenho dos modelos, optando por discutir o impacto dessas soluções quando aplicadas a problemas em AVAs. Isso evidencia que tais soluções não substituem o papel dos professores, tutores e gestores, mas são utilizadas como uma forma de semi-automatização do trabalho, permitindo tomadas de decisões mais rápidas e fundamentadas em dados (Borges; Nogueira e Barbosa, 2016; Gkонтzis *et al.*, 2017; Distante *et al.*, 2014; Maina; Oboko e Waiganjo, 2017; Valsamidis *et al.*, 2012).

A partir das evidências encontradas e discutidas pelas respostas das questões de pesquisas anteriores, pode-se afirmar existir direcionamentos claros para a construção de um projeto de AM para ser aplicado a diferentes problemas oriundos de fóruns e AVAs. Descreve-se a seguir duas possíveis estratégias para projetos de AM, organizadas pelos autores a partir de observações feitas a partir da análise dos estudos.

Para **Procedimentos para dados estruturados**, tem-se que para dados como *logs* e metadados, os seguintes procedimentos seriam necessários: coleta; pré-processamento com filtragem de dados faltantes, remoção de inconsistências nos dados; engenharia de atributos com seleção de um subconjunto de atributos (uso de técnicas como *Select K Best*), redução de dimensionalidade espacial ou construção de indicadores a partir de observações de especialistas do domínio; construção do modelo preditivo ou descritivo (utilizando a técnica de treinamento de modelos mais citada pelos trabalhos, validação cruzada em k partes (Pong-inwong e Rungworawut, 2012; Bosch *et al.*, 2018; Maina; Oboko e Waiganjo, 2017; Romero *et al.*, 2013; Olivé *et al.*, 2018; Barbosa *et al.*, 2020; Barbosa *et al.*, 2021)); e interpretação dos resultados dos modelos, por exemplo, com avaliação de atributos mais importantes para uma previsão.

Já para **Procedimentos para dados não estruturados**, tais como texto, mantêm-se a estrutura anterior, apenas modificando o passo de pré-processamento, onde sugere-se aplicar os seguintes procedimentos: remoção de caracteres inválidos, remoção de *stop words*, aplicação de *stemming* e codificação dos dados (uso de TF-IDF ou *BERT* para sentenças).

Um ponto que se demonstra um **desafio** analisado pela RSL é que os conjuntos de dados analisados e apresentados por esses trabalhos em sua maioria não são disponibilizados. Aliado a isso, alguns estudos não apresentam os resultados dos modelos por meio de métricas, o que impacta em possíveis comparações com estudos semelhantes e o entendimento do desempenho do ponto de vista computacional, representando um desafio para a tentativa de replicação das metodologias dos trabalhos, produção de modelos que façam boas generalizações e a realização de comparação com outras soluções (Borges; Nogueira e Barbosa, 2016; Gkantzis *et al.*, 2017; Maina; Oboko e Waiganjo, 2017; Husni; Jumaat e Tasir, 2022; Valsamidis *et al.*, 2012; Saleh; Iriarte e Chang, 2022).

#### **4. Conclusões e Limitações**

Esta RSL apresentou um panorama do uso de AM aplicado a extração de informações a partir das interações dos fóruns de AVAs. Foi possível discutir aspectos que envolvem um projeto de AM e seu impacto na educação. Elementos como conjunto de dados, procedimentos de pré-processamento, estratégias de engenharia de atributos e de avaliação de modelos, algoritmos e tarefas de AM foram abordados por essa RSL. Outro elemento discutido foi o quanto um projeto de AM pode beneficiar as atividades em um AVA.

Como limitações têm-se o uso de um **Escopo restrito** de uma análise específica no uso de dados de fóruns como objeto de aprendizado dos modelos de AM. Adicionando como restrição um uso claro e evidente de fóruns por partes das soluções dos problemas investigados pelos estudos. Para garantir essa abordagem específica, o presente trabalho fez uso de uma *string* de busca que limitasse os resultados aos estudos que além de mencionar ao longo do seu texto principal os termos centrais apresentados pela RSL, fizesse o uso da palavra central “Fórum” e seus sinônimos em seu resumo (*abstract*), como forma de garantir um escopo restrito em volta de fóruns. Contudo, com essa escolha é possível que alguns trabalhos que atendem aos critérios de inclusão, que não sigam essa restrição adicional, não foram coletados e, consequentemente, não fossem lidos. Os trabalhos que lidam com **MOOCs não fazem parte do escopo da RSL**, porém, entende-se por parte dos autores como limitação dessa RSL a exclusão deles. Tendo em vista que o grande uso de MOOCs possibilita que diversos estudos apresentem processos compatíveis com a educação superior. **Avaliação de qualidade:** A presente RSL não faz avaliação e seleção de trabalhos a partir da sua qualidade de publicação.

#### **Referências**

- Alachiotis, N. S.; Stavropoulos, E. C.; Verykios, V. S. Analyzing learners behavior and resources effectiveness in a distance learning course: A case study of the hellenic open university. **Journal of Information Science Theory and Practice**, Korea Institute of Science and Technology Information, v. 7, n. 3, p. 6 – 20, 2019. ISSN 22879099. Cited by: 4. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85075379258&doi=10.1633\%2fJISTaP.2019.7.3.1&partnerID=40&md5=7a151eb5969d0fd57b3c2cce256d8ccf>>.
- Barbosa, A.; Ferreira, M.; Mello, R. F.; Lins, R. D.; Gasevic, D. The impact of automatic

- text translation on classification of online discussions for social and cognitive presences. In: **LAK21: 11th International Learning Analytics and Knowledge Conference**. New York, NY, USA: Association for Computing Machinery, 2021. (LAK21), p. 77–87. ISBN 9781450389358. Disponível em: <<https://doi.org/10.1145/3448139.3448147>>.
- Barbosa, G. *et al.* Towards automatic cross-language classification of cognitive presence in online discussions. In: **Proceedings of the Tenth International Conference on Learning Analytics & Knowledge**. New York, NY, USA: Association for Computing Machinery, 2020. (LAK '20), p. 605–614. ISBN 9781450377126. Disponível em: <<https://doi.org/10.1145/3375462.3375496>>.
- Borges, V. A.; Nogueira, B. M.; Barbosa, E. F. A multidimensional data model for the analysis of learning management systems under different perspectives. In: **2016 IEEE Frontiers in Education Conference (FIE)**. [S.l.: s.n.], 2016. p. 1–8.
- Bosch, N. *et al.* Modeling key differences in underrepresented students' interactions with an online stem course. In: **Proceedings of the Technology, Mind, and Society**. New York, NY, USA: Association for Computing Machinery, 2018. (TechMindSociety '18). ISBN 9781450354202. Disponível em: <<https://doi.org/10.1145/3183654.3183681>>.
- Cerulo, L.; Distante, D. Topic-driven semi-automatic reorganization of online discussion forums: A case study in an e-learning context. In: **IEEE Global Engineering Education Conference, EDUCON 2013, Berlin, Germany, March 13-15, 2013**. IEEE, 2013. p. 303–310. Disponível em: <<https://doi.org/10.1109/EduCon.2013.6530121>>.
- Crossley, S.; Paquette, L.; Dascalu, M.; McNamara, D. S.; Baker, R. S. Combining click-stream data with nlp tools to better understand mooc completion. In: **Proceedings of the Sixth International Conference on Learning Analytics & Knowledge**. New York, NY, USA: Association for Computing Machinery, 2016. (LAK '16), p. 6–14. ISBN 9781450341905. Disponível em: <<https://doi.org/10.1145/2883851.2883931>>.
- Distante, D.; Cerulo, L.; Visaggio, A.; Leone, M. Enhancing online discussion forums with a topic-driven navigational paradigm: A plugin for the moodle learning management system. In: A., F.; J., F.; J., F. (Ed.). INSTICC Press, 2014. p. 97 – 106. ISBN 978-989758048-2. Cited by: 2. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84909982155&doi=10.5220\%2f0005078600970106&partnerID=40&md5=f6ab10253475a436eec6014f7e402613>>.
- Doleck, T.; Lemay, D. J.; Brinton, C. G. Evaluating the efficiency of social learning networks: Perspectives for harnessing learning analytics to improve discussions. **Computers Education**, v. 164, p. 104124, 2021. ISSN 0360-1315. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360131521000014>>.
- Erlin; Rio, U.; Rahmiati. Text message categorization of collaborative learning skills in online discussion using support vector machine. In: **2013 International Conference on Computer, Control, Informatics and Its Applications (IC3INA)**. [S.l.: s.n.], 2013. p. 295–300.
- Gkонтзис, А. Ф.; Karachristos, С. В.; Panagiotakopoulos, С. Т.; Stavropoulos, Е. С.; Verykios, В. С. Sentiment analysis to track emotion and polarity in student fora. In: **Proceedings of the 21st Pan-Hellenic Conference on Informatics**. New York, NY, USA: Association for Computing Machinery, 2017. (PCI '17). ISBN 9781450353557. Disponível em: <<https://doi.org/10.1145/3139367.3139389>>.
- Husni, N. H. A.; Jumaat, N. F.; Tasir, Z. Investigating student's cognitive engagement, motivation and cognitive retention in learning management system. **International Journal of Emerging Technologies in Learning**, International Association of Online Engineering, v. 17, n. 9, p. 184 – 200, 2022. ISSN 18688799. Cited by: 3; All Open Access, Gold Open Access. Disponível em:

- [⟨https://www.scopus.com/inward/record.uri?eid=2-s2.0-85130400649&doi=10.3991%\%2fijet.v17i09.29727&partnerID=40&md5=b4fb28e18b3eb089b4ec3f548c7aaaf1⟩.](https://www.scopus.com/inward/record.uri?eid=2-s2.0-85130400649&doi=10.3991\%2fijet.v17i09.29727&partnerID=40&md5=b4fb28e18b3eb089b4ec3f548c7aaaf1)
- Kitchenham, B.; Charters, S. Guidelines for performing systematic literature reviews in software engineering. v. 2, 01 2007.
- Kovanović, V.; Gašević, D.; Joksimović, S.; Hatala, M.; Adesope, O. Analytics of communities of inquiry: Effects of learning technology use on cognitive presence in asynchronous online discussions. **The Internet and Higher Education**, v. 27, p. 74–89, 2015. ISSN 1096-7516. Disponível em: ⟨https://www.sciencedirect.com/science/article/pii/S1096751615000421⟩.
- Loncar, M.; Barrett, N. E.; Liu, G.-Z. Towards the refinement of forum and asynchronous online discussion in educational contexts worldwide: Trends and investigative approaches within a dominant research paradigm. **Computers Education**, v. 73, p. 93–110, 2014. ISSN 0360-1315. Disponível em: ⟨https://www.sciencedirect.com/science/article/pii/S036013151300331X⟩.
- López, S. L. S.; Redondo, R. P. D.; Vilas, A. F. Can the type of content you share on elearning forums reveal what kind of student you are? **IEEE Revista Iberoamericana de Tecnologias del Aprendizaje**, v. 16, n. 3, p. 318–327, Aug 2021. ISSN 1932-8540.
- Maina, E. M.; Oboko, R. O.; Waiganjo, P. W. Using machine learning techniques to support group formation in an online collaborative learning environment. **International Journal of Intelligent Systems and Applications**, Modern Education and Computer Science Press, v. 9, n. 3, p. 26 – 33, 2017. ISSN 2074904X. Cited by: 15; All Open Access, Bronze Open Access. Disponível em: ⟨https://www.scopus.com/inward/record.uri?eid=2-s2.0-85014461169&doi=10.5815%\%2fijisa.2017.03.04&partnerID=40&md5=01b0ec8c008256161fb9e4e1cbebb917⟩.
- Murad, D. F.; Heryadi, Y.; Isa, S. M. A.; Budiharto, W.; Wijanarko, B. D. Text mining analysis in the log discussion forum for online learning recommendation systems. In: . Institute of Electrical and Electronics Engineers Inc., 2018. p. 421 – 426. ISBN 978-153867422-2. Cited by: 3. Disponível em: ⟨https://www.scopus.com/inward/record.uri?eid=2-s2.0-85074198148&doi=10.1109%\%2fISRITI.2018.8864246&partnerID=40&md5=f7ef6ce903f20fa02db4f377d7fb0590⟩.
- Neto, V. et al. Automatic content analysis of online discussions for cognitive presence: A study of the generalizability across educational contexts. **IEEE Transactions on Learning Technologies**, v. 14, n. 3, p. 299–312, 2021.
- Norz, L.-M.; Dornauer, V.; Hackl, W. O.; Ammenwerth, E. Measuring social presence in online-based learning: An exploratory path analysis using log data and social network analysis. **The Internet and Higher Education**, v. 56, p. 100894, 2023. ISSN 1096-7516. Disponível em: ⟨https://www.sciencedirect.com/science/article/pii/S1096751622000501⟩.
- Olivé, D. M.; Huynh, D. Q.; Reynolds, M.; Dougiamas, M.; Wiese, D. A supervised learning framework for learning management systems. In: **Proceedings of the First International Conference on Data Science, E-Learning and Information Systems**. New York, NY, USA: Association for Computing Machinery, 2018. (DATA '18). ISBN 9781450365369. Disponível em: ⟨https://doi.org/10.1145/3279996.3280014⟩.
- Papamitsiou, Z.; Economides, A. A. Learning analytics and educational data mining in practice: A systematic literature review of empirical evidence. **Journal of Educational Technology Society**, International Forum of Educational Technology Society, v. 17, n. 4, p. 49–64, 2014. ISSN 11763647, 14364522. Disponível em: ⟨http://www.jstor.org/stable/jeductechsoci.17.4.49⟩.

- Pong-inwong, C.; Rungworawut, W. Teaching evaluation using data mining on moodle lms forum. In: **2012 6th International Conference on New Trends in Information Science, Service Science and Data Mining (ISSDM2012)**. [S.l.: s.n.], 2012. p. 550–555.
- Raschka, S.; Mirjalili, V. **Python Machine Learning**. 3. ed. Birmingham, UK: Packt Publishing, 2019. 748 p. ISBN 978-1789955750.
- Romero, C.; López, M.-I.; Luna, J.-M.; Ventura, S. Predicting students' final performance from participation in on-line discussion forums. **Computers Education**, v. 68, p. 458–472, 2013. ISSN 0360-1315. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360131513001607>>.
- Ruipérez-Valiente, J. A. *et al.* Data-driven detection and characterization of communities of accounts collaborating in moocs. **Future Generation Computer Systems**, v. 125, p. 590–603, 2021. ISSN 0167-739X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167739X21002570>>.
- Saleh, M.; Iriarte, M. F.; Chang, M. Ask4summary: A summary generation moodle plugin using natural language processing techniques. In: S., I. *et al.* (Ed.). Asia-Pacific Society for Computers in Education, 2022. v. 1, p. 549 – 554. ISBN 978-986972149-3. Cited by: 1. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85151062432&partnerID=40&md5=96aa747e02dddd2cd224a5494697110e>>.
- Sha, L.; Raković, M.; Das, A.; Gašević, D.; Chen, G. Leveraging class balancing techniques to alleviate algorithmic bias for predictive tasks in education. **IEEE Transactions on Learning Technologies**, v. 15, n. 4, p. 481–492, Aug 2022. ISSN 1939-1382.
- Sha, L. *et al.* Is the latest the greatest? a comparative study of automatic approaches for classifying educational forum posts. **IEEE Transactions on Learning Technologies**, p. 1–14, 2022. ISSN 1939-1382.
- Sheshadri, A.; Gitinabard, N.; Lynch, C. F.; Barnes, T.; Heckman, S. Predicting student performance based on online study habits: A study of blended courses. In: K.E., B.; M., Y. (Ed.). International Educational Data Mining Society, 2018. Cited by: 10. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85084014565&partnerID=40&md5=91f9f6c249948a133d905b695cee029e>>.
- Siksnelyte-Butkiene, I.; Streimikiene, D.; Lekavicius, V.; Balezentis, T. Energy poverty indicators: A systematic literature review and comprehensive analysis of integrity. **Sustainable Cities and Society**, v. 67, p. 102756, 2021. ISSN 2210-6707. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2210670721000500>>.
- Tamada, M. M.; Netto, J. F. de M.; Lima, D. P. R. de. Predicting and reducing dropout in virtual learning using machine learning techniques: A systematic review. In: **2019 IEEE Frontiers in Education Conference (FIE)**. [S.l.: s.n.], 2019. p. 1–9.
- Tobarra, L.; Robles-Gómez, A.; Ros, S.; Hernández, R.; Caminero, A. C. Analyzing the students' behavior and relevant topics in virtual learning communities. **Computers in Human Behavior**, v. 31, p. 659–669, 2014. ISSN 0747-5632. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0747563213003518>>.
- Valsamidis, S.; Kontogiannis, S.; Kazanidis, I.; Theodosiou, T.; Karakos, A. A clustering methodology of web log data for learning management systems. **Educational Technology and Society**, International Forum of Educational Technology and Society, National Taiwan Normal University, v. 15, n. 2, p. 154 – 167, 2012. ISSN 11763647. Cited by: 43. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84871580422&partnerID=40&md5=d72d8f939fdcc7f54af0d4f670d9f7a6>>.

Wei, X.; Jia, H. A review of the application of artificial intelligence in the virtual learning environment. In: **2021 Tenth International Conference of Educational Innovation through Technology (EITT)**. [S.l.: s.n.], 2021. p. 79–82.

Wohlin, C. *et al.* **Experimentation in Software Engineering**. [S.l.]: Springer Publishing Company, Incorporated, 2012. ISBN 3642290434.