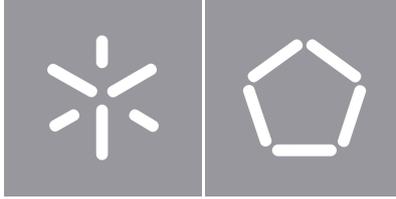


Universidade do Minho
Escola de Engenharia

Maria Sofia Martinho Gonçalves Jordão Marques

**Modelos de análise preditiva
para a tomada de decisão**



Universidade do Minho
Escola de Engenharia

Maria Sofia Martinho Gonçalves Jordão Marques

**Modelos de análise preditiva
para a tomada de decisão**

Dissertação de Mestrado
Mestrado em Engenharia Informática

Trabalho efetuado sob a orientação de
Paulo Jorge Freitas de Oliveira Novais
Dalila Alves Durães

Direitos de Autor e Condições de Utilização do Trabalho por Terceiros

Este é um trabalho académico que pode ser utilizado por terceiros desde que respeitadas as regras e boas práticas internacionalmente aceites, no que concerne aos direitos de autor e direitos conexos.

Assim, o presente trabalho pode ser utilizado nos termos previstos na licença abaixo indicada.

Caso o utilizador necessite de permissão para poder fazer um uso do trabalho em condições não previstas no licenciamento indicado, deverá contactar o autor, através do RepositóriUM da Universidade do Minho.

Licença concedida aos utilizadores deste trabalho:



CC BY

<https://creativecommons.org/licenses/by/4.0/>

Agradecimentos

Quero agradecer a todos que me apoiaram e acompanham nesta jornada.

À minha família, agradeço a paciência e carinho que me dispensaram. Sem dúvida são os alicerces de tudo que sou.

Aos meus amigos e aos colegas de estudo, um obrigado pela atenção que me dispensaram. Sempre prontos a motivar-me e apoiar-me no dia a dia, particularmente nas fases do projeto mais complexas e desmotivadoras, fazendo-me acreditar nas minhas capacidades.

Um agradecimento muito particular à minha coorientadora, Doutora Dalila Durães e ao Professor Doutor Paulo Novais meu orientador, que, com muita paciência, facilitaram esta caminhada. O meu grande obrigado.

Agora esperam-me outros desafios onde conto com todos, e onde todos podem contar comigo.

A todos os que contribuíram para o meu sucesso, o mais sincero obrigado,

Declaração de Integridade

Declaro ter atuado com integridade na elaboração do presente trabalho académico e confirmo que não recorri à prática de plágio nem a qualquer forma de utilização indevida ou falsificação de informações ou resultados em nenhuma das etapas conducente à sua elaboração.

Mais declaro que conheço e que respeitei o Código de Conduta Ética da Universidade do Minho.

Universidade do Minho, Braga, novembro 2023

Maria Sofia Martinho Gonçalves Jordão Marques

Resumo

Hoje, e de acordo com os dados disponibilizados pela pordata relativos ao ano 2021, cerca de 8,3% dos alunos do ensino secundário, e 9,8% dos alunos do ensino básico, das escolas portuguesas, ficam retidos ou abandonam os sistemas educacionais [dos Santos \[2021\]](#). No entanto, Portugal não é o país com nível mais baixo de taxa de abandono e insucesso escolar, sendo que muitos países da união europeia encontram um enorme desafio em atingir as metas definidas pela Comissão Europeia, [UE \[2021\]](#).

Uma vez que, a educação é um dos pilares do desenvolvimento de um país, é importante compreender quais as razões por detrás destas estatísticas, e descobrir o que leva os alunos a terem tal insucesso de forma a tentar mitigar estes resultados. Para tal, é necessário adquirir dados a respeito dos alunos para realizar a sua análise, surgindo assim a área de Educational Data Mining (EDM).

A previsão precoce do insucesso escolar pode ser a peça chave do esforço para o evitar. Para além desta, uma outra parte crucial é o desenvolvimento de um sistema de apoio à tomada de decisão que permita as entidades competentes aplicar estratégias de prevenção aquando das previsões apresentadas.

Na sequencia desta necessidade, é proposto o desenvolvimento de um sistema de apoio à tomada de decisão, que utiliza por base modelos de análise preditiva de alunos em risco de insucesso ou abandono escolar.

Palavras-chave Inteligência Artificial, Machine Learning, Deep Learning, Educational Data Mining, Decision Support Systems, Educational DSS

Abstract

Today, according to data made available by Pordata for the year 2021, about 8.3% of secondary school students in Portuguese schools fail or drop out of the educational system, another 9.8% of students in this situation are still in primary education [dos Santos \[2021\]](#). However, Portugal is not the country with the lowest dropout and school failure rate, as many European Union countries face a huge challenge in achieving the targets set by the European Commission, [UE \[2021\]](#).

Since education is one of the pillars of a country's development, it is important to understand the reasons behind these statistics and discover what leads students to such failure in order to try to mitigate these results. In order to do so, it is necessary to acquire data about the students, thus emerging the area of Educational Data Mining (EDM).

Early prediction of school failure can be the key piece of the effort to avoid it. In addition to this, another crucial part is the development of a decision support system that allows the competent entities to apply prevention strategies when predictions are made.

Following this need, it is proposed to develop a decision support system that uses predictive analysis models of students at risk of failure or dropout as a basis.

Keywords Artificial Intelligence, Machine Learning, Deep Learning, Educational Data Mining, Decision Support Systems, Educational DSS

Conteúdo

I	Material Introdutório	1
1	Introdução	2
1.1	Contexto e Motivação	2
1.2	Objetivos	3
1.3	Metodologia	4
1.4	Questões de Investigação	5
1.5	Estrutura da Dissertação	6
2	Estado da arte	7
2.1	Conceitos e Tecnologias	7
2.1.1	Inteligência Artificial	7
2.1.2	Educational Data Mining	10
2.2	Revisão da Literatura	11
2.3	Multi-Criteria Decision Making Methods	26
2.3.1	Métodos de atribuição de pesos	27
2.3.2	Métodos para classificação de alternativas	37
2.4	Educational Decision Support Systems	47
II	Core da Dissertação	49
3	Métodos e Metodologias	50
3.1	Proposta de Arquitetura	50
3.2	Dataset	52
3.3	Requisitos Funcionais e não funcionais	53

4	Aplicações	55
4.1	Tratamento de dados	55
4.2	Modelos Preditivos	60
4.2.1	Avaliação	61
4.2.2	Resultados e Discussão	61
4.3	Multi-Criteria Decision Making Methods	65
4.3.1	Resultados	68
4.3.2	Discussão dos resultados	82
5	Conclusões e trabalho futuro	86
5.1	Questões de investigação	87
5.1.1	Que modelos de <i>machine learning</i> obtêm melhores resultados na área da educação ?	87
5.1.2	Que métodos multi-critério de apoio à tomada de decisão obtêm melhores resultados na área da educação ?	88
5.1.3	Que vantagens se podem obter dos sistemas de apoio à decisão na educação ?	89
5.2	Disseminação de resultados	89
5.3	Perspetiva de trabalho futuro	90

Lista de Figuras

- 1 Etapas da metodologia DSR Lobato [2022]. 5
- 2 Inteligência Artificial, *Machine learning* e *Deep learning* AI [2018] 8
- 3 Inteligência Artificial TAI [2022] 9
- 4 Etapas de MCDM Taherdoost and Madanchian [2023] 27
- 5 Escala Saaty Ariff et al. [2008] 29
- 6 Random Index Saaty Ammarapala et al. [2018] 30
- 7 Proposta de arquitetura geral 50
- 8 Proposta de arquitetura detalhada 51

Lista de Tabelas

1	Resumo dos artigos selecionados - modelos preditivos	17
2	Resumo dos artigos selecionados - MCDM	24
3	Dados do Dataset Original	53
4	Variáveis com valores nulos	56
5	<i>Dataset Final</i>	58
6	Perfis de risco	60
7	Caption	62
8	Teste componentes PCA	62
9	Classification report - Cluster 0	63
10	Classification report - Cluster 1	64
11	Classification report - Cluster 2	64
12	Classification report - Cluster 3	65
13	Atribuição de Pesos	66
14	Matriz de comparações pareadas - AHP	68
15	Vetor de pesos - AHP	69
16	Caption	69
17	Resultados alunos Alto Risco - AHP	69
18	Resultados alunos Baixo Risco - AHP	70
19	Vetor de pesos - EWM	71
20	Resultados alunos Alto Risco - EWM	72
21	Resultados alunos Baixo Risco - EWM	72
22	Resultados alunos Alto Risco- SAW	73
23	Resultados alunos Baixo Risco - SAW	73
24	Resultados alunos Alto Risco - TOPSIS	74

25	Resultados alunos Baixo Risco - TOPSIS	74
26	Resultados alunos Alto Risco- MOORA	75
27	Resultados alunos Baixo Risco - MOORA	75
28	Resultados alunos Alto Risco- SAW-TOPSIS	76
29	Resultados alunos Baixo Risco - SAW-TOPSIS	76
30	Resultados alunos Alto Risco- AHP-TOPSIS	78
31	Resultados alunos Baixo Risco - AHP-TOPSIS	78
32	Resultados alunos Alto Risco- AHP-MOORA	79
33	Resultados alunos Baixo Risco - AHP-MOORA	79
34	Resultados alunos Alto Risco- EWM-TOPSIS	80
35	Resultados alunos Baixo Risco - EWM-TOPSIS	80
36	Resultados alunos Alto Risco- EWM-MOORA	81
37	Resultados alunos Baixo Risco - EWM-MOORA	81
38	Ranking dos alunos de alto risco	82
39	Ranking dos alunos de alto risco	84

Acrónimos

AHP Analytic Hierarchy Process.

EDM Educational Data Mining.

EDSS Educational Decision Support Systems.

EWM Entropy Weight.

IA Inteligência Artificial.

MCDM Multi-Criteria Decision Making Methods.

MOORA Multi-Objective Optimization based on Ration Analysis.

SAW Simple Additive Weighting.

TOPSIS Technique for Order Preference by Similarity to Ideal Solution.

Parte I
Material Introdutório

Capítulo 1

Introdução

1.1 Contexto e Motivação

A educação é um processo de aquisição de conhecimentos, habilidades, valores e hábitos por meio de diversas formas de aprendizagem. É essencial para o desenvolvimento humano e é um dos pilares para a integração de um indivíduo na sociedade.

A Declaração Universal dos Direitos Humanos estabelece que todos têm direito à educação [ONU \[1948\]](#), que ensina as pessoas a encontrar estratégias, interagir, refletir, tomar decisões e resolver problemas, além de adquirir conhecimentos científicos. No entanto, nem todos os estudantes conseguem alcançar o sucesso desejado. Existem muitos fatores que podem contribuir para as dificuldades académicas ou para o insucesso escolar, tais como:

- Motivação;
- Maus hábitos de estudo ou organização;
- Acesso limitado a recursos ou suporte;
- Problemas pessoais ou familiares;
- Comportamento perturbador ou absentismo.

A taxa de abandono na educação e formação tem sido o principal indicador, a nível europeu, da evolução dos sistemas educativos, uma vez que é reconhecida a sua centralidade, nas sociedades de hoje, para a competitividade económica, a coesão social e a igualdade de oportunidades.

De acordo com os dados disponibilizados pela eurostat, grande parte dos países da União Europeia encontram uma taxa de abandono precoce superior a 10%, sendo para estes um enorme desafio atingir as metas definidas pela Comissão Europeia [UE \[2021\]](#), de uma taxa inferior a 9% até 2030. De igual

forma sucede o desafio de atingir as metas estabelecidas a nível da taxa de aproveitamento escolar, onde cerca de 23% dos estudantes de 15 anos, apresentam um fraco aproveitamento a matemática, ciência e leitura, longe dos 15% alvo.

Assim, se um aluno se encontra em risco de insucesso é importante identificar a causa subjacente e tratá-la para melhorar as suas hipóteses de sucesso. O desafio que se coloca é desenvolver tecnologias para prever o risco de insucesso dos alunos antecipadamente de forma a preveni-lo.

Daí, apareceu o conceito de *Educational Data Mining* (EDM), esta foca-se na aplicação de técnicas de mineração de dados no campo da educação. A EDM é usada principalmente para desenvolver modelos precisos que preveem aos desempenhos dos alunos, a fim de melhorar as experiências de aprendizagem, apresentando grande potencial para melhorar a qualidade das instituições e sistemas educacionais.

Um Sistema de Suporte à Decisão (DSS) é uma solução de tecnologia baseada em computador que pode ser usada para apoiar a tomada de decisões complexas e a solução de problemas [Shim et al. \[2002\]](#). Assim, quando aplicado à área da educação um DSS pode fornecer o estudo e otimização de abordagens de previsão de resultados dos alunos [Scholar et al. \[2021\]](#) permitindo um processo de tomada de decisão informado.

Está projetado para apoiar a tomada de decisões, proporcionando acesso aos dados relevantes e ferramentas analíticas e apresentando as informações de maneira fácil de compreender e usar. Este é denominado *Educational Decision Support System*(EDSS).

Assim, a principal motivação para o desenvolvimento de um sistemas de suporte à tomada de decisão na educação, para a identificação previa de alunos em risco de abandono ou insucesso escolar, surge da necessidade de diminuir a taxa de reprovação e abandono dos estudantes, fortalecendo o ambiente educacional melhorando os métodos pedagógicos.

1.2 Objetivos

O objetivo geral pretende utilizar os modelos de análise preditiva para desenvolver um sistema de apoio à decisão. Com isto, o objetivo geral será considerar vários modelos e algoritmos de *machine learning* no sentido de, por um lado, tendo em conta os dados e as informações disponíveis, treiná-los de modo a detetar os fenómenos atrás descritos sempre que novos dados e informações sejam fornecidos à plataforma.

Perante tal, especificam-se alguns objetivos tais como:

- Estudo de modelos de *machine learning* e *deep learning* para análise preditiva existentes no estado

de arte.

- Estudo do estado de arte dos sistemas de suporte à decisão existente.
- Aplicação e treino de alguns modelos em casos reais.
- Comparação dos resultados e refinamento dos modelos.
- Desenvolvimento de um pequeno módulo de suporte à tomada de decisão.

1.3 Metodologia

O desenvolvimento e investigação científica exige planeamento e preparação antes de se obter quaisquer resultados. A metodologia escolhida deve estar alinhada com os objetivos da pesquisa para otimizar o processo. Assim sendo, a estratégia escolhida para este projeto é a metodologia Design Science Research (DSR).

Esta é uma metodologia de pesquisa que se concentra na criação e avaliação da eficácia de artefactos ou soluções que abordam problemas do mundo real. O objetivo principal do DSR é avançar o estado do conhecimento e da prática, desenvolvendo e avaliando novas soluções num campo específico.

A *Design Science Research* (DSR) tem emergido como um método apropriado em diversas investigações no campo da educação, ao caracterizar-se como um tipo de pesquisa em desenvolvimento, a DSR pode contribuir na construção de protótipos e artefactos educacionais significativos. [Alan Cesar \[2020\]](#)

A metodologia DSR é uma metodologia científica rigorosa que contém os procedimentos e métodos corretos que devem ser seguidos para alcançar as soluções e objetivos estabelecidos. Esta metodologia envolve uma série de etapas que devem ser seguidas, para que os procedimentos científicos tenham sucesso, sendo estas: identificação de problemas, design, implementação, avaliação e disseminação.

- Identificação do problema e motivação: a investigação deve conduzir a um artefacto relevante que pode ser uma teoria, um método, ou uma construção
- Definição dos objectivos de uma solução: definir porque é que as soluções pretendidas são relevantes para a área científica específica
- Concepção e desenvolvimento: as características da solução como qualidade, funcionalidade, adequação e relevância devem ser previamente definidas em função dos objectivos da investigação

- Demonstração: Desenvolvimento de métodos de estimativa que podem prever o resultado da solução pretendida
- Avaliação: Validação da solução, comparando o resultado previsto no processo de demonstração com os objectivos da solução que foram definidos no início
- Comunicação: A investigação e os seus problemas devem ser apresentados a um público orientado para a tecnologia

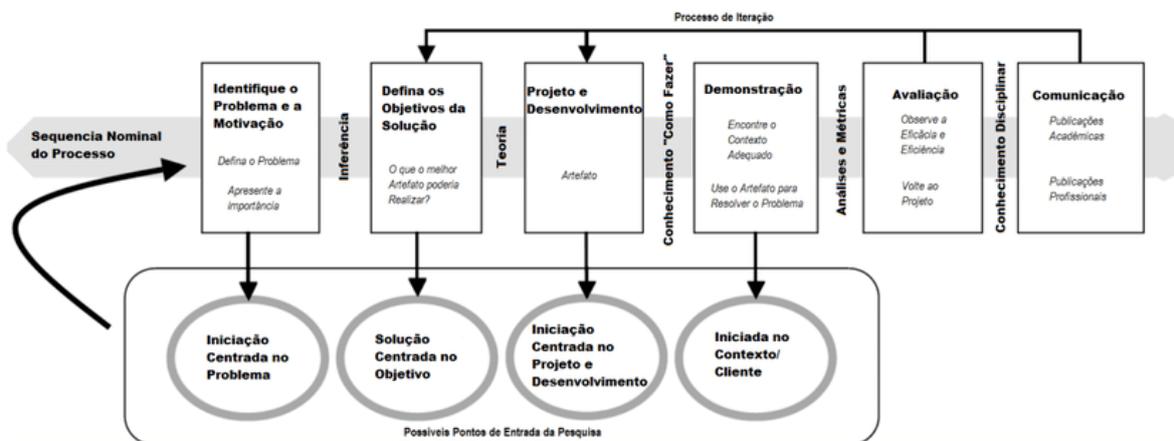


Figura 1: Etapas da metodologia DSR Lobato [2022].

1.4 Questões de Investigação

O uso de modelos de *machine learning* e sistemas de suporte à decisão (DSS) na educação tem se tornado cada vez mais prevalente nos últimos anos, e apresentam grande potencial em melhorar significativamente o processo de tomada de decisões e aumentar o sucesso dos alunos. No entanto, há um debate constante sobre quais os modelos e métodos mais eficazes nesse contexto e quais são as vantagens específicas do uso de um DSS na educação. Tendo isso em o foco as questões de investigação a serem abordadas são:

Q11: Que modelos de machine learning obtêm melhores resultados na área da educação ?

Q12: Que métodos multi-critério de apoio à tomada de decisão obtêm melhores resultados na área da educação ?

Q13: Que vantagens se podem obter dos sistemas de apoio à decisão na educação ?

1.5 Estrutura da Dissertação

Este trabalho compreende cinco capítulos. Neste primeiro capítulo pretende-se auxiliar o leitor a compreender o contexto e as motivações subjacentes ao estudo deste projeto, juntamente com os objetivos propostos, a metodologia utilizada e as questões de investigação base para esta dissertação.

O segundo capítulo apresenta conceitos e tecnologias utilizadas, a revisão da literatura e os métodos de decisão multi-critério.

No terceiro capítulo é apresentada uma proposta de arquitetura do trabalho desenvolvida, o dataset e os requisitos funcionais e não funcionais.

No quarto capítulo é detalhado o processo de tratamento de dados, destacando as etapas e técnicas envolvidas. Além disso, é apresentada uma análise dos resultados obtidos pelos modelos e métodos aplicados.

Por fim, no último capítulo são abordadas as respostas às questões de investigação que englobam este projeto. Nele é realizada uma discussão concisa do trabalho desenvolvido e destacadas as contribuições significativas deste trabalho para o campo de estudo.

Capítulo 2

Estado da arte

2.1 Conceitos e Tecnologias

2.1.1 Inteligência Artificial

A **Inteligência Artificial** é a simulação da inteligência humana em máquinas programadas para pensar e aprender como humanos [AI \[2018\]](#). Os sistemas de IA são projetados para executar tarefas que normalmente requerem inteligência humana, como percepção visual, reconhecimento de fala, tomada de decisões e tradução de idiomas.

Os avanços em *machine learning* e *deep learning* são a principal razão pela qual a inteligência artificial está a desenvolver-se tão rapidamente e porque o paradigma da indústria tecnológica está em mudança [TAI \[2022\]](#).

A inteligência artificial tem o potencial de revolucionar a educação, fornecendo experiências de aprendizagem personalizadas, automatizando tarefas repetitivas e aprimorando a eficiência e eficácia geral do processo de aprendizagem. Uma das maneiras pelas quais a IA está a ser utilizada na educação é por meio do desenvolvimento de algoritmos de aprendizagem personalizados que podem se adaptar às necessidades e estilos de aprendizagem exclusivos de cada aluno. Esses sistemas permitem analisar os dados de desempenho do aluno e ajustar o currículo e os métodos de ensino de acordo para garantir que cada aluno esteja a progredir no seu próprio ritmo ideal [Livieris et al. \[2016\]](#).

Chatbots e assistentes virtuais com tecnologia IA, também, são um excelente exemplo, uma vez que disponibilizam suporte 24 horas por dia, 7 dias por semana aos alunos, permitindo que eles obtenham respostas para as suas perguntas e recebam assistência nos seus estudos a qualquer momento. A IA, também, pode automatizar tarefas repetitivas, como atribuir notas e fornecer feedback sobre as tarefas dos alunos, permitindo que os professores passem mais tempo em tarefas mais importantes, como fornecer instruções e orientação individualizada [Faria \[2022\]](#).

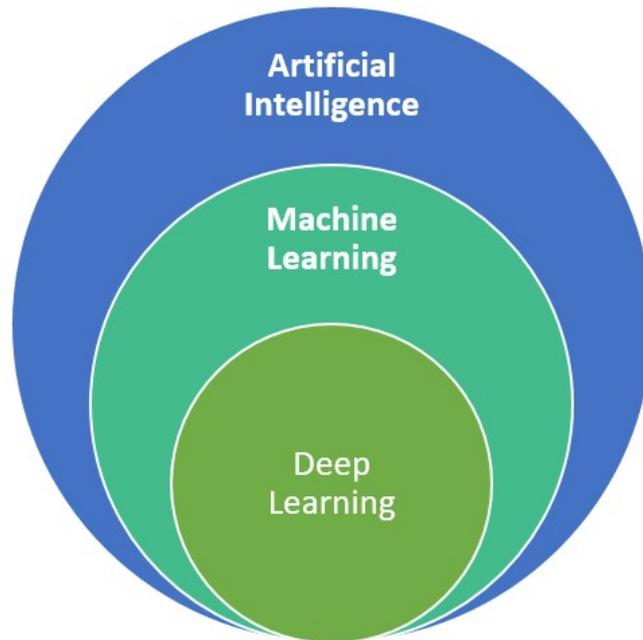


Figura 2: Inteligência Artificial, *Machine learning* e *Deep learning* AI [2018]

A IA pode ainda melhorar a eficiência geral do sistema educacional, analisando grandes conjuntos de dados sobre o desempenho dos alunos e identificando padrões que podem informar e levar ao desenvolvimento de métodos de ensino mais eficazes [Cardona \[2020\]](#). No entanto, vale a pena observar que a IA na educação ainda está no primórdio e mais pesquisa e desenvolvimento são necessários para entender totalmente o seu potencial.

Machine Learning é um subconjunto da inteligência artificial que permite que os computadores aprendam e melhorem com a experiência, sem serem explicitamente programados. Baseia-se na ideia de que os sistemas podem aprender com os dados, identificar padrões e tomar decisões com o mínimo de intervenção humana [Singh et al. \[2007\]](#). Os algoritmos de machine learning podem ser amplamente categorizados em três grupos:

- *Supervised Learning*: neste tipo de aprendizagem, o modelo é treinado em dados rotulados, onde a saída desejada já é conhecida. O algoritmo aprende a mapear entradas para a saída correta.
- *Unsupervised Learning*: neste tipo de aprendizagem, o modelo não recebe dados rotulados e deve encontrar estrutura e significado nos dados de entrada por conta própria.
- *Reinforcement Learning*: este tipo de aprendizagem é usado para treinar modelos para tomar uma sequência de decisões. O algoritmo aprende por tentativa erro e recebe feedback na forma de recompensas ou penalizações para determinadas ações.

AI Artificial Intelligence	<ul style="list-style-type: none"> • Reactive Machines • Limited Memory • Theory of Mind • Self-awareness
ML Machine Learning	<ul style="list-style-type: none"> • Supervised Learning • Unsupervised Learning • Reinforcement Learning
DL Deep Learning	<ul style="list-style-type: none"> • Convolutional Neural Network (CNN) • Recurrent Neural Network (RNN) • Generative Adversarial Network (GAN) • Deep Belief Network (DBN)

Figura 3: Inteligência Artificial TAI [2022]

Machine learning tem sido explorado na educação e tem demonstrado grande potencial em transformar a educação, tornando-a mais personalizada, eficiente e eficaz.

Deep learning é um subconjunto de *Machine Learning* baseado em redes neurais artificiais (ANNs) com muitas camadas, também conhecidas como redes neurais profundas (DNNs). Essas redes são projetadas para aprender representações de dados de forma automática e adaptativa com vários níveis de abstração [Mathew et al. \[2021\]](#).

Os algoritmos de deep learning são particularmente úteis para tarefas que envolvem dados não estruturados, como imagens, vídeos e áudio. Eles têm sido utilizados para obter desempenho de ponta em tarefas como reconhecimento de imagem e fala, processamento de linguagem natural e visão computacional.

O tipo mais comum de deep learning são as Redes Neurais Convolucionais (CNNs), que são usadas para classificação de imagens e tarefas de detecção de objetos. Redes neurais recorrentes (RNNs) são outro tipo de redes de deep learning usadas para dados sequenciais, como séries temporais, fala ou texto [Mathew et al. \[2021\]](#). Os algoritmos de deep learning exigem grandes quantidades de dados e poder computacional, mas com o avanço do hardware e a disponibilidade de big data, tornou-se possível treinar redes neurais profundas de maneira eficaz.

Deep learning tal como machine learning tem o potencial de revolucionar a educação, fornecendo experiências de aprendizagem mais personalizadas e eficazes.

No entanto, é importante observar que o deep learning, tal como o machine learning, ainda são uma tecnologia relativamente nova na educação e mais pesquisas são necessárias para entender completamente seu potencial e limitações. Além disso, a implementação de deep learning nos sistemas educacionais requer muitos dados e é importante garantir que os dados sejam recolhidos e usados de

forma ética [Prabhu \[2019\]](#).

2.1.2 Educational Data Mining

A educação refere-se ao processo de aquisição de conhecimentos, habilidades, valores, crenças e hábitos. Pode ocorrer em ambientes formais ou informais e pode ser autodirigida ou dirigida por outros. A educação é frequentemente dividida em diferentes níveis, como educação primária, secundária e superior, também pode ser descrita como ensino básico, secundário e superior [Phauk and Okazaki \[2020b\]](#).

A educação formal geralmente refere-se à educação fornecida por escolas, faculdades e universidades e geralmente é estruturada com um currículo e um conjunto de metas e objetivos. A educação informal refere-se à educação que ocorre fora do sistema educacional formal, como por meio de grupos comunitários, bibliotecas e outras organizações [Cardona et al. \[2016\]](#).

O objetivo da educação é ajudar os indivíduos a desenvolver o conhecimento e as habilidades de que precisam para serem bem-sucedidos na vida. A educação também desempenha um papel importante no desenvolvimento pessoal, bem como no desenvolvimento da sociedade como um todo. Por meio da educação, as pessoas adquirem a capacidade de pensar criticamente, resolver problemas e tomar decisões informadas, essenciais para participar numa sociedade e contribuir para a economia [Essa and Ayad \[2012\]](#).

No contexto da educação em ciência da computação, a reprovação do aluno pode se referir à incapacidade do aluno atender aos padrões acadêmicos ou passar nos requisitos do curso. Isso pode incluir fatores como baixo desempenho em exames, notas baixas e falha em concluir tarefas ou projetos [Cardona \[2020\]](#). De acordo com [Prioste \[2020\]](#), o fracasso do aluno pode ser causado por vários fatores, incluindo falta de conhecimento, dificuldade em entender o conteúdo lecionado, maus hábitos de estudo ou indisciplina, falta de envolvimento e falta de apoio e estímulo por parte de professores e/ou família .

É importante observar que o fracasso do aluno nem sempre é resultado da falta de habilidade ou esforço do mesmo. Por vezes, o problema pode ser relacionado com a maneira como o material está a ser ensinado ou com os recursos disponíveis.

Educational Data Mining (EDM) pode ser usado para entender o estilo de aprendizagem e o comportamento do aluno e prever seu fracasso, o que pode ajudar os educadores a tomar ações antecipadas para fornecer suporte e orientação [Heba. M. Rashad \[2013\]](#).

A EDM é o processo de usar técnicas de mineração de dados para analisar dados de sistemas educacionais, a fim de extrair informações e conhecimentos úteis [de Baker et al. \[2008\]](#). Isso pode incluir dados de desempenho do aluno, dados de avaliação e dados sobre interações e comportamento do mesmo.

O objetivo da mineração de dados educacionais é melhorar a eficácia e a eficiência da educação, fornecendo informações sobre o aprendizado do aluno e identificando padrões e tendências que podem informar a tomada de decisões.

Existem várias técnicas diferentes usadas na mineração de dados educacionais, incluindo [de Baker et al. \[2008\]](#):

- *Clustering*: agrupar alunos em grupos semelhantes com base nas suas características.
- Classificação: prever os resultados dos alunos ou agrupar os alunos em categorias predefinidas.
- *Association rule mining*: identificando relações entre variáveis em dados de alunos.
- *Sequential pattern mining*: identificando padrões no comportamento do aluno ao longo do tempo.
- Visualização: criar representações gráficas dos dados do aluno para facilitar a sua compreensão e análise.

Assim de uma forma geral, podemos retirar que EDM é uma área, preocupada em desenvolver métodos para explorar dados provenientes de ambientes educacionais e com estes compreender melhor os alunos e os ambientes em que aprendem. [de Baker et al. \[2008\]](#) Conforme poderemos observar no seguintes capítulos, as áreas de atuação dos EDMs podem ser muito diversificadas, indo desde a identificação de alunos em risco, previsões do desempenho do aluno. De uma forma geral, a utilização de EDM visa continuamente melhorar o sistema educacional. [Heba. M. Rashad \[2013\]](#)

2.2 Revisão da Literatura

Os sistemas de apoio à decisão educacional (EDSS) são sistemas baseados em computador que ajudam educadores e organizações educacionais a tomar decisões informadas sobre o ensino e a aprendizagem.

Um EDSS pode usar técnicas de mineração de dados para analisar os dados de desempenho do aluno, a fim de identificar padrões e tendências que podem ser usados para apoiar a tomada de decisões relacionadas à aprendizagem do mesmo. Também pode usar ferramentas de visualização de dados para apresentar os mesmos de forma intuitiva, permitindo que os formadores tomem decisões sustentadas. [Heba. M. Rashad \[2013\]](#)

Embora o EDSS esteja a ser amplamente estudado no ensino superior, tem sido pouco exploradas as suas capacidades para o ensino básico e secundário, uma conclusão que é possível de retirar pela falta de artigos publicados nesta área de atuação. No ensino superior, o EDSS tem sido maioritariamente utilizado

para dar suporte à alocação de recursos e análise de aprendizagem, bem como para analisar os dados de desempenho dos alunos para identificar fatores que contribuem para o sucesso do mesmo. [Carneiro et al. \[2019\]](#),

Nas escolas primárias e secundárias, o EDSS pode ser utilizado para apoiar a aprendizagem personalizada e a análise do desempenho do aluno, bem como para identificar padrões e tendências no envolvimento e comportamento do aluno. [Uvalieva and Smailova \[2014\]](#), [Scholar et al. \[2021\]](#), [Kotsiantis \[2012\]](#), [Faria \[2022\]](#).

Apesar dos EDSSs terem um potencial para serem benéficos na educação, é importante considerar possíveis limitações e desafios.

Um grande desafio, consiste na utilização destes sistemas para problemas que trabalham com *data-sets* desbalanceados. Por exemplo, no caso de estudo para a previsão de alunos em risco de insucesso escolar, este é um grande desafio, uma vez que a percentagem de alunos em risco de retenção é sempre inferior ao número de alunos com aproveitamento escolar. Em tais condições, a *accuracy* pode ser uma medida enganosa pois num classificador tradicional a classe maioritária vai obter alta *accuracy*, enquanto que a classe minoritária é ignorada. Portanto, é necessário um algoritmo específico capaz de focar nas classes minoritárias, ou então tomar em atenção este aspeto no processo de pré-processamento e limpeza de dados, [Chau and Phung \[2013\]](#).

Além disso, pode haver preocupações sobre a precisão e grau de confiança dos dados usados pelos EDSSs, uma vez que, para obter decisões mais fidedignas, os dados fornecidos devem estar atualizados e devem ser consistentes, algo que raramente se verifica. Questões relacionadas à privacidade e segurança dos dados, também podem ser levantadas, [IEEE \[2015\]](#).

Na secção que se segue, é feita uma discussão dos estudos que aplicam modelos de aprendizagem para a previsão de taxas de insucesso e abandono no ensino básico e, também, superior.

Foram realizados múltiplos estudos sobre a eficácia dos EDSSs na melhoria dos resultados educacionais, e o seu potencial em fornecer atividades de aprendizagem personalizadas para as necessidades dos alunos. [Uvalieva and Smailova \[2014\]](#)

Uma revisão desses estudos constatou que os EDSSs têm não só o potencial para melhorar o desempenho dos alunos, como também, são fonte de informação e *insights* que permite uma melhor preparação dos processos académicos nos anos seguintes. [Scholar et al. \[2021\]](#)

Em [Livieris et al. \[2019\]](#), um EDSS foi desenvolvido no âmbito da educação em *Lyceum*, no sentido de prever a performance dos alunos ao longo do ano escolar, mais especificamente de forma a identificar precocemente alunos em risco de falhar as avaliações finais. Neste caso de estudo foram analisados

dados, provenientes da *microsoft showcase school 'Avgoulea-Linardatou'*, relativamente a 2260 alunos, recolhidos entre 2007 a 2016 no curso de álgebra e geometria, contendo informações sobre o desempenho dos alunos, como notas orais, notas de testes e notas de exames finais. Este estudo mostrou a aplicação individual de vários métodos de classificação tais como, *artificial neural networks* (ANN) mais especificamente os algoritmos *Multi-Layer Perceptron* e RBF, SVM mais especificamente SMO, *Naive Bayes* como algoritmo representante das *Bayesian networks*, *Decision Tree* (DT) mais especificamente o algoritmo C4.5 e ainda *logistic model tree*. Foram ainda selecionados dois algoritmos tradicionais de *rule-learning*, o JRip e o PART. Por fim foram ainda aplicados os algoritmos 3-NN e 10-NN. Neste caso de estudo em particular a solução obtida foi um algoritmo de classificação de 2 níveis. Isto é um tipo de algoritmo de *supervised learning* que é usado para classificar objetos em duas categorias diferentes. Ele funciona dividindo o processo de classificação em dois passos: primeiro, ele realiza uma classificação inicial para determinar a qual das duas categorias o objeto pertence, e em seguida, realiza uma classificação secundária para determinar a qual subcategoria dentro dessa categoria o objeto pertence. O melhor desempenho foi obtido para o caso em que o C4.5 foi selecionado como classificador de nível A e SMO como Nível B, obtendo uma *accuracy* de cerca de 84% para alunos em risco de não obterem aproveitamento no exame final, usando apenas os dados relativos ao primeiro semestre. E uma *accuracy* de cerca de 85% usando dados do primeiro e segundo semestre. O modelo desenvolvido também permitiu obter *accuracy* de cerca de 91% relativamente a nota final do aluno, para ambos os casos. Este artigo foi uma melhoria do estudo realizado anteriormente [Livieris et al. \[2016\]](#) em 2016.

Em [Kužnar and Gams \[2016\]](#), foi desenvolvido um sistema no contexto da educação na Eslovénia onde a taxa de abandono e insucesso escolar é muito elevada, este sistema denominado Metis foi criado para a deteção e prevenção previa de estudantes do ensino médio em risco de insucesso escolar. O objetivo deste sistema consiste então em melhorar o processo educacional existente prevendo o fracasso do estudante e fornecer ferramentas na forma de aplicações de telemóvel para aplicar medidas preventivas e mitigar os resultados negativos. Neste caso de estudo foram analisados 692 estudantes do ensino médio, contendo informações desde notas a registos de presenças. O Metis no entanto não deixa de ser um EDSS uma vez que é através da visualização dos dados e previsões que um professor averigua a necessidade de um aluno aderir as medidas de prevenção ou não. Neste modelo, ao contrário da maioria, as previsões são feitas diariamente ou semanalmente. Sendo que todos os dias são recolhidos "snapshots" dos dados, criando um novo *dataset*. Após cada "snapshot", os conjuntos de dados foram integrados em um único dataset de aprendizagem, onde cada instância corresponde a um determinado ponto no tempo. Múltiplos métodos foram aplicados, tais como, Naive Bayes, Logistic Regression, Decision Tree, Random Forest e

SVM, de forma a encontrar o que melhor que se adaptava ao problema em questão, sendo neste caso *Logistic Regression* com uma *precision* de 56% e 61% para o primeiro e segundo semestre respetivamente, e uma *recall* de 72% no primeiro semestre e 74% no segundo.

Um outro estudo utilizando *machine learning* foi realizado no âmbito da previsão antecipada de alunos em risco abandono escolar. Márquez-Vera C [2016]. Neste artigo é desenvolvido um algoritmo designado ICMR2 baseado em *Grammar-based genetic programming* (GBGP). O dataset utilizado contem dados relativos a 419 alunos, matriculados na Unidade Académica Preparatória da Universidade Autónoma de Zacatecas no México. De forma a compararem o desempenho do algoritmo desenvolvido foram testados multiplos algoritmos desde, Naive Bayes, SMO, *classification rules*, mais especificamente *JRip*, Decison Trees como foi o caso do J48. Para a realização do estudo foram considerados sete momentos, espaçados dentre o primeiro semestre, para a averiguar qual o melhor momento e quais os melhores *features* para a previsão. Do primeiro ao terceiro momento, datado entre o inicio e o meio do primeiro semestre. Do quarto ao sexto, sucede entre o meio do semestre e o fim do mesmo. Sendo o sétimo e ultimo momento o inicio do novo período escolar. Foram testados três cenários, um com todos os dados disponíveis, outro aplicando *feature selection*, e outro aplicando reamostragem. Após análise dos resultados, verificou-se que o método proposto superou os algoritmos de classificação tradicionais, sendo que o modelo conseguiu prever o abandono em apenas quatro semanas, após inicio das aulas, com uma *accuracy* de 83,22% e 99,8% ao fim de 14 semanas, que corresponde a meio do semestre. Conclui-se ainda que os *features* mais importantes para a previsão consistiram nas notas, informação relativa a estrutura e organização da sala de aula, registo de presenças, informação pessoal do aluno e hábitos de estudo. Uma vez que o algoritmo utilizado consiste num algoritmo *white-box* é bastante fiável a utilização do mesmo para o desenvolvimento de um EDSS.

Em Cardona [2020], é feita uma revisão sistemática de modelos de previsão de alunos em risco de retenção usando técnicas de *machine learning*. Ao longo do artigo são referidos alguns estudos, relevantes, como é o caso de Essa and Ayad [2012], onde é desenvolvido um mecanismo de modelagem preditiva que usa inteligência máquina e técnicas estatísticas para identificar previamente alunos em risco. Este sistema, é um EDSS, uma vez que fornece um conjunto de visualizações de dados avançadas para retirar informações de diagnóstico e uma ferramenta para gerir casos de intervenções necessárias. A interface de visualização mostra informações como o nível de preparação para a faculdade, índice de sucesso, presença nas aulas, participação, nota a disciplina e a previsão de nota. As principais fontes de dados deste estudo advém de um *learning management system* (LMS) e *web logs*, sendo estes capturados todos os dias para cada aluno e processados usando técnicas de *machine learning* para gerar uma previsão do

risco de abandono. Semelhante ao artigo [Kužnar and Gams \[2016\]](#), o sistema de sucesso do aluno interage com o próprio por meio de um aplicativo móvel ou navegador de *desktop*. Aqui a previsão da classificação final do aluno em risco de abandono escolar foi feita por meio de um conjunto de diferentes algoritmos, não especificados. Um outro estudo levou a cabo o desenvolvimento de uma plataforma de recomendação para fornecer suporte direto baseado em sistemas, a alunos em risco de retenção explorando para tal modelos de *machine learning* [Embarak \[2021\]](#). Neste caso de estudo, foi usado um conjunto de dados de 460 alunos do ensino superior para avaliar seu desempenho, contendo informação sobre as admissões dos mesmos, incluindo notas a matemática, inglês e ensino médio geral. Dentre os modelos utilizados, como Rule Induction, Random Forest e Naive Bayes, destacou-se a Decision Tree, alcançando 82,68% de *accuracy*. Além disso, o modelo foi capaz de prever com precisão 89,85% dos casos em que o aluno tem bom desempenho escolar e 60,47% dos casos em que o aluno está em risco.

Uma nova revisão sistemática sobre a previsão de reprovação do aluno importante de mencionar é realizada por [Velooso \[2022\]](#), neste estudo são abordados múltiplos artigos relevantes ao tema de técnicas de EDM para a previsão de alunos em risco.

Dos mais importantes de referir temos um estudo que pretendeu determinar os fatores críticos que afetam o desempenho dos alunos no ensino médio e construir um modelo de classificação eficiente por meio da fusão de classificadores simples e baseados em ensemble para a previsão do desempenho acadêmico. [Siddique et al. \[2021\]](#) O conjunto de dados foi coletado usando uma pesquisa online e física de quatro escolas secundárias diferentes baseadas nas características acadêmicas, demográficas, sociais e familiares dos estudantes, contendo 1227 registros. Em primeiro lugar, três classificadores simples, incluindo um Multilayer Perceptron (MLP), J48 e PART, foram observados juntamente com três algoritmos ensemble bem estabelecidos abrangendo Bagging (BAG), MultiBoost (MB) e Voting (VT) independentemente. Para melhorar ainda mais o desempenho dos classificadores mencionados acima, alguns foram posteriormente unidos, resultando em 9 modelos. Os resultados da avaliação mostraram que o MultiBoost com MLP superou os outros ao atingir 98,7% de *accuracy*, 98,6% de precisão, recall e F-score. O estudo sugere que o modelo proposto pode ser útil para identificar o desempenho acadêmico de alunos do ensino médio em um estágio inicial para melhorar os resultados de aprendizagem. [Phauk and Okazaki \[2020b\]](#) Lançou uma proposta de novas técnicas de mineração de dados para educação e um sistema baseado em web capaz de prever alunos com baixo desempenho. Os dados utilizados neste estudo foram obtidos através de questionários online realizados em várias escolas secundárias no Camboja. O conjunto de dados final contém 43 *features*, abrangendo informações pessoais, fatores domésticos, fatores individuais e registros de presença. Para o modelo, 4 algoritmos diferentes foram testados: K-Nearest

Neighbour, Hybrid C5.0, Hybrid RF e *Improved deep Believe Networks*. O metodo Hybrid RF produziu a melhor *accuracy* com 99,95%. Safira Begum [2022] implementa algoritmos para prever o desempenho dos alunos. O *dataset* aborda o desempenho dos estudantes no ensino secundário de duas escolas portuguesas. Os atributos de dados incluem notas dos alunos, características demográficas, sociais e relacionadas à escola) e foi obtido usando relatórios escolares e questionários. Inicialmente constroem dois conjuntos de dados: um para matemática, com 395 entradas, e outro para aulas de português, com 649 entradas. Depois aplicaram três algoritmos e uma versão otimizada de cada um, e os algoritmos são: Boosting, Bagging and Random subspace algorithms. A versão otimizada consiste em desenvolver Algoritmos Genéticos com o intuito de tentar melhorar o algoritmo tradicional. O melhor algoritmo foi o Boosting, com uma *accuracy* de 98,11% para a previsão em matemática e 96,82% para português.

Finalizando, a pesquisa sugere que os EDSSs têm um excelente potencial de apoio a tomada de decisões educacionais, podendo ser uma mais valia para os formadores identificarem de forma previa os alunos em risco de falhar o ano escolar, permitindo agir conforme as necessidades do aluno, a tempo de melhoria. No entanto, é importante considerar cuidadosamente as necessidades específicas e o contexto de um determinado ambiente educacional e abordar quaisquer possíveis desafios ou limitações na implementação de um EDSS.

Tabela 1: Resumo dos artigos selecionados - modelos preditivos

Autores	Objetivo	Atributos	Metodo e Performance
Livieris et al. [2019]	Identificar precocemente alunos em risco de falhar as avaliações finais	Notas orais, notas de testes e notas de exames finais	Um algoritmo de classificação de 2 níveis, C4.5 e SMO <i>accuracy</i> de 84%
Kužnar and Gams [2016]	Identificar precocemente alunos com fraco aproveitamento	Notas, registos de presenças e registos escolar sobre o percurso académico	<i>Logistic Regression</i> com <i>precision</i> de 56% e 61% para o 1º e 2º semestre
Márquez-Vera C [2016]	Previsão antecipada de alunos em risco abandono e insucesso escolar	Notas, info. relativa a estrutura e organização da sala de aula, registo de presenças, info. pessoal do aluno e hábitos de estudo	GBGP - ICMR2 com uma <i>accuracy</i> de 83,22% ao fim de 4 semanas
Siddique et al. [2021]	Identificar com antecedência o desempenho académico dos alunos do ensino médio para evitar insucesso escolar	Notas, características demográficas, sociais e familiares dos estudantes	MultiBoost ensemble com MLP com uma <i>accuracy</i> de 98,7%
Phauk and Okazaki [2020b]	Um sistema web-based capaz de prever alunos com baixo desempenho	Fatores socioeconómicos, nível de educação dos pais, fatores académicos como nível de motivação, e ainda atributos relativos à estrutura das aulas	Hybrid RF com <i>accuracy</i> de 99.9%
Embarak [2021]	Identifique os alunos em risco com antecedência	Notas a matemática e inglês	Decision Tree com <i>accuracy</i> de 82,68%.
Safira Begum [2022]	Prever o desempenho dos alunos nas aulas de matemática e português	Género do aluno, situação familiar, hábitos estudo e características demográficas	Boosting com uma <i>accuracy</i> de 98,11% para matemática e 96,82% para português

Conforme é possível constatar pela revisão da literatura, os modelos de previsão variam dependendo do objetivo do estudo, por exemplo, [Kužnar and Gams \[2016\]](#) quer resultados de previsão com antecedência capturando informação por semana enquanto os restantes estudos o fariam por semestre ou até

mesmo por ano (variação de estudo). Mesmo quando os estudos compartilham o objetivo, os modelos de previsão variam. Portanto, não seria adequado indicar que há uma única técnica certa de *machine learning* a ser aplicada para a previsão da retenção e/ou abandono de estudantes. No entanto, pode-se concluir que as técnicas de *machine learning*, em geral, oferecem boa *accuracy* com uma média de 85% num intervalo entre 56% e 99%.

Relativamente aos atributos selecionados para a previsão, a literatura indica que a importância dos fatores muda de acordo com a instituição e metodologia aplicada. Uma das razões por detrás dessas diferenças advém do facto que os estudos têm alguns objetivos diferentes, como prever para um curso específico ou para um período de tempo diferente. Assim, os resultados de cada modelo dependem das informações disponíveis para o estudo.

Contudo, foi possível identificar diferentes categorias de informações que mostraram ser importantes em todos os estudos incluídos nesta revisão. De fato, é evidente que as notas são um atributo de grande importância para a previsão da retenção de estudantes, apresentando-se na totalidade dos estudos, seguido por fatores como o registo de presenças e registos pessoais como situação financeira, grau de escolaridade dos encarregados de educação, entre outros, que se apresentam em maioria destes estudos. Assim, noutras palavras, autores diferentes usam estratégias diferentes, no entanto, estes parecem concordar que as características relacionadas ao progresso escolar do estudante são as mais importantes.

Um dos principais problemas da tomada de decisão, tem como objetivo determinar a melhor alternativa considerando mais do que um critério no processo de seleção. *Multi-criteria decision-making* (MCDM) são sistemas de apoio à decisão, que ajudam a solucionar problemas que possuem vários objetivos, frequentemente conflitantes, com múltiplas ações possíveis, incertezas, várias etapas, e diversos indivíduos afetados pela decisão. Estes são considerados uns dos métodos mais precisos de tomada de decisão, e podem ser conhecido como uma revolução na área de *decision making* [Taherdoost and Madanchian \[2023\]](#)

Existem vários tipos de métodos MCDM que foram desenvolvidos e aprimorados por múltiplos autores nas últimas décadas. As principais diferenças entre esses métodos estão relacionadas ao nível de complexidade dos algoritmos, aos métodos de atribuição de pesos aos critérios, à forma de representação dos critérios de avaliação de preferências, à possibilidade de dados incertos e, por fim, ao tipo de agregação de dados [Bączkiewicz et al. \[2021\]](#)

MCDMs possuem diversas aplicações em diferentes disciplinas e áreas, que vão desde economia e finanças até medicina e educação. A determinação da performance dos alunos, por sua própria natureza,

é um conceito multidimensional que inclui várias variáveis, onde a implementação destas técnicas são adequadas.

Um dos métodos mais utilizados pela sua robustez é o método TOPSIS proposto por [Hwang and Yoon \[1981\]](#).

Em [Blasco-Blasco et al. \[2021\]](#) é estudada a utilização de uma variante deste método, o unweighted-TOPSIS (uwTOPSIS), no âmbito de medir e avaliar a performance dos alunos da universidade de ciências e engenharia de Santander, Colômbia. Este estudo foi realizado num dataset com 2975 alunos de 1º ano, contendo informações relativas ao seu estado económico, social, académico, cognitivo e de saúde. Este método, ao contrario do método tradicional *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS), proposto por Liern e Pérez-Gladish [Liern and Gladish \[2022\]](#), não exige que seja determinado em ante mão a importância relativa de cada critério, tornando o método mais robusto, uma vez que os resultados não dependem mais de pequenas variações desses pesos, e as decisões tornam-se mais estáveis. [Liern and Gladish \[2022\]](#) Para a construção deste indicador de performance académica foram identificados 5 passos. O primeiro consistiu em determinar um framework conceptual que permitisse identificar os fenómenos a serem avaliados. O segundo passo consistiu na obtenção do dataset, seleção das variáveis e análise dos dados. O terceiro passo consistiu na normalização dos dados. O quarto passo consistiu na aplicação do método uwTOPSIS e por fim, no quinto passo, foi feita a comparação das alternativas e a análise dos resultados. O indicador proposto, permitiu que a instituição académica obtivesse o valor do indicador para cada estudante e soubesse se houve ou não uma melhoria nos seus resultados. Neste estudo e com os dados analisados, a instituição garantiu uma melhoria nos resultados dos estudantes que apresentaram deficiências no início do semestre, melhorando os resultados académicos e reduzindo a taxa de desistência e abandono escolar.

[Wati et al. \[2018\]](#) Este artigo procura avaliar o desempenho académico dos estudantes utilizando *Multi-Objective Optimization by Ratio Analysis* (MOORA) e *Simple Multi-Attribute Rating* (SMART) onde os pesos dos critérios e subcritérios são resultantes da entropia e ganho. O objetivo desta pesquisa é ajudar o instrutor a determinar o peso dos critérios dos estudantes para futuras recomendações e avaliações do desempenho dos mesmos, uma vez que os resultados desta pesquisa constituem um ranking desde os alunos mais prováveis de terminar o curso dentro do tempo estipulado aos alunos com maiores dificuldades.

Neste artigo [Wati et al. \[2018\]](#), o dataset é gerado a partir dos dados dos graduados na Faculdade de Ciência da Computação e Tecnologia da Informação (FKTI) da Universidade Mulawarman (Unmul), no período de julho de 2015 a dezembro de 2017. Este dataset contém informação de 450 alunos,

referente ao gênero, idade, naturalidade e as notas dos alunos. Esse conjunto de dados foi utilizado para implementar pesos de entropia nos métodos MOORA e SMART no processo de classificação do desempenho acadêmico dos estudantes. Esta pesquisa utiliza o valor de entropia de cada subcritério como peso do subcritério. Enquanto o ganho é o resultado do atributo selecionado usando entropia para determinar o melhor atributo. Neste estudo observou-se que o critério da média do quarto ano teve o maior impacto na avaliação acadêmica do estudante. Para medir o desempenho dos métodos MOORA e SMART utilizando pesos de entropia para classificar as alternativas, foi utilizada uma matriz de confusão para avaliar o desempenho acadêmico dos estudantes. A classificação das alternativas descreve que quanto maior o peso da alternativa, melhor será o desempenho acadêmico do estudante e menor será o tempo para concluir o estudo. Neste artigo, a *precision* e a *accuracy* do MOORA e SMART são calculadas utilizando a matriz de confusão. O resultado mostrou uma *accuracy* de 60,9% e uma *precision* de aproximadamente 53% para ambos os métodos, com um valor de *precision* ligeiramente superior para o método MOORA. Assim, neste estudo a instituição conseguiu, não só identificar com base na entropia os principais critérios com maior impacto no desempenho acadêmico dos alunos, mas também, com base nesses resultados garantir um apoio e conseqüente melhoria daqueles estudantes com uma maior dificuldade de aprendizagem.

Em [Bagi et al. \[2020\]](#) procura-se solucionar os problemas típicos da seleção manual das melhores alternativas. Neste caso procura-se selecionar alunos com alto desempenho acadêmico, utilizando uma amostra de dados de notas de estudantes obtidos pela SMPN 11 Dumoga. Neste, foi desenvolvido um sistema de apoio à decisão utilizando AHP para determinar o peso dos critérios e o TOPSIS para determinar qual a melhor alternativa. Este sistema de apoio à decisão utiliza o AHP e o TOPSIS como ferramenta de suporte ao comitê de seleção na escolha de estudantes de alto desempenho, como também resolve problemas, desde a redução do tempo necessário para o processo de seleção. Além disso, torna os resultados da seleção mais objetivos. O AHP possui uma característica única de fornecer um procedimento significativo e confiável para determinar a importância relativa de diferentes atributos em relação ao objetivo. No dataset constou informação como o valor médio das notas, presença, atitude, atividades extra curriculares e cartas de recomendação. Os pesos relativos ou importância dos critérios foram obtidos através de entrevistas realizadas pelo comitê de seleção. Depois de atribuídos os pesos relativos ao método AHP, estes são tratados, obtendo como resultado os pesos definitivos de cada critério. De seguida é aplicado o método TOPSIS que utilizando os pesos obtidos posteriormente pelo AHP determina com base no seu algoritmo as soluções ideais, correspondendo aos alunos com maior performance acadêmica, e as soluções ideais negativas que correspondem aos alunos com pior performance acadêmica.

A comparação dos resultados foi feita com os resultados obtidos manualmente, observando-se apenas uma discrepância relativamente ao aluno em primeiro lugar na classificação. Uma possível explicação para essa diferença recai na falta de objetividade por parte do comitê de seleção. Nem a precisão nem a accuracy são mencionadas neste artigo.

[Marbun et al. \[2021\]](#) estuda a utilização individual de métodos para a seleção dos alunos merecedores de bolsa de estudo, SAW, WP, TOPSIS. Neste estudo, foram realizados estudos de caso em universidades que forneceriam bolsas de estudo para a educação PPA (*Program Participation Agreement*) concedidas pelo Ministério da Pesquisa, Tecnologia e Ensino Superior. As variáveis de pesquisa são os atributos ou critérios determinados pela Direktorat Jenderal Pembelajaran dan Kemahasiswaan, conforme declarado no guia do PPA de 2018. Os critérios são os requisitos que os estudantes devem cumprir para serem determinados como beneficiários de bolsas de estudo. Os dados são fornecidos pelas universidades participantes e contêm informação relativamente a média das notas do aluno, número de créditos, atividades extra curriculares e rendimento familiar. A importância/ pesos relativos a cada critério foram dados com base nos requisitos estabelecido pelo Ministério da Pesquisa, Tecnologia e Ensino Superior. Após a aplicação dos três métodos foi possível observar que tanto o SAW como o WP obtiveram os mesmo resultados, sendo que o TOPSIS obteve resultados bastante diferentes, esta diferença advém do facto da maior importância/peso definitivo nos dois primeiros métodos ter sido atribuída a media enquanto que para o TOPSIS o critério com maior importância era o rendimento familiar. Os resultados de classificação de cada método podem então fornecer recomendações adequadas para a tomada de decisão na determinação da concessão de bolsas de estudo PPA aos estudantes que merecem recebê-las.

[Rianto et al. \[2017\]](#) tal como [Bagi et al. \[2020\]](#) é mais uma vez estudado o funcionamento dos métodos AHP e TOPSIS em simultâneo como decision support system. Onde o AHP é usado para encontrar o peso dos critérios no processo de seleção com base no valor de importância, enquanto o método TOPSIS é usado para encontrar o valor de classificação de cada candidato. O objetivo principal deste artigo é a seleção de novos estudantes universitários e para previsão da sua futura empregabilidade. Foi utilizada uma amostra de 30 estudantes do Diploma 3 de Aeronáutica da STTA de Yogyakarta, onde foram utilizados indicadores de competências académicas, domínio da língua inglesa, testes psicológicos, habilidades interpessoais (comunicação, resolução de problemas e pensamento crítico, gestão de tempo, cooperação e habilidades de adaptação) e atitudes. Inicialmente, os investigadores utilizaram as entrevistas aos especialistas que consistiam em comitê de seleção de estudantes universitários, chefes de departamentos e departamentos de cooperação para obter a pontuação de interesse para cada critério e subcritério. De seguida foi aplicado o método AHP onde foi observado que o atributo com maior importância foram as

atitudes, seguido das habilidades interpessoais. Portanto, a atitude torna-se o fator mais importante, pois está relacionada ao interesse dos futuros estudantes pelo trabalho que escolherão. Após calculado o peso global para cada critério pelo AHP estes foram utilizados como entrada para o método TOPSIS, que de seguida atribuiu uma pontuação a cada candidato. A partir dos resultados da análise, em comparação com a amostra real utilizada, obteve-se um valor de accuracy de 86,66%. Pode-se concluir através dos resultados obtidos que os estudantes classificados em primeiro lugar possuem maior habilidade, tanto acadêmica quanto não acadêmica, em termos de desempenho requerido no local de trabalho. Este modelo pode ser utilizado para reduzir as fraquezas humanas na tomada de decisões, proporcionando resultados mais precisos.

Outras aplicações destes métodos foram estudadas em diversas áreas para além da performance acadêmica, como é o caso de [Sari et al. \[2017\]](#), neste estudo procura-se desenvolver um sistema de tomada de decisão aquando da seleção de trabalhadores para uma empresa, de forma a garantir que são selecionados os trabalhadores mais apropriados para o trabalho e assim responder as necessidades da empresa. Este artigo procura resolver os erros na seleção de cvs devido ao grande número de arquivos que precisam ser combinados com muitos critérios desejados pela empresa, simplificando o processo de tomada de decisão através do método do Processo Hierárquico Analítico (AHP).

O Processo Hierárquico Analítico (AHP) é um dos modelos de tomada de decisão de múltiplos critérios que podem ajudar o ser humano a estruturar fatores lógicos, experiência ou conhecimento, emoções e senso de otimização em um processo sistemático. [Sari et al. \[2017\]](#) Este método tem sido amplamente utilizado para selecionar a melhor alternativa entre várias alternativas com base em múltiplos critérios, este implica na estruturação de critérios de múltiplas opções em uma hierarquia de sistema, comparando alternativas para cada critério específico e definindo a importância média das alternativas.

Neste estudo, [Sari et al. \[2017\]](#), inicialmente foram definidos os critérios de avaliação e de seguida os dados a analisar. Os dados foram obtidos a partir de observação direta e entrevistas com o chefe de recursos humanos da empresa. Para este estudo foram considerados dados a nível da educação, experiência de trabalho, idade e estado civil de trabalhadores entrevistados na empresa Asia Exotica. Inicialmente atribui-se os pesos aos critérios conforme a sua importância para a empresa no momento da seleção e de seguida é aplicado o método. De seguida esses pesos são atribuídos aos candidatos. Por fim o método devolve uma lista com as classificações de cada candidato, desde o mais classificado para a posição ao menos classificado. Este sistema procura dispensar seleções manuais que muitas vezes são subjetivas e onde ocorre muitos erros quando há muitos candidatos em questão e múltiplos critérios a considerar. Neste artigo foi obtida uma accuracy de 80 a 90 % quando comparado ao método manual.

Na pesquisa realizada em [Firgiawan et al. \[2020\]](#), o objetivo é comparar os 4 métodos de Sistemas de Apoio à Decisão (DSS) utilizados no processo de tomada de decisão: Simple Additive Weighting (SAW), Technique for Order Preference by Similarity to Ideal Solution (TOPSIS), uma combinação de Simple Additive Weighting (SAW) e Analytical Hierarchy Process (AHP), e Technique for Order Preference by Similarity to Ideal Solution (TOPSIS) e Analytical Hierarchy Process (AHP), usados na determinação das propinas dos alunos na Indonésia de acordo com critérios estabelecidos. Aqui as propinas são determinadas em grupos diferentes, em que cada grupo tem uma porcentagem que foi definida pelo governo com base na capacidade financeira de cada aluno. Essas porcentagens são baseadas na regulamentação do Ministério da Educação e Cultura da República da Indonésia número 55 de 2013, bem como os pesos/importância dos critérios.

Os dados utilizados pertencem a estudantes da Universitas Sulawesi Barat, contendo informação relativamente ao rendimento familiar, condições de habitação e despesas. [Firgiawan et al. \[2020\]](#)

Com base nos resultados do cálculo da precisão de cada método utilizando a análise manual dos dados, o melhor método a ser utilizado é o método TOPSIS-AHP com uma accuracy de 80%. Isso deve-se ao fato de que o AHP possui o valor de accuracy mais alto em comparação com os outros métodos, atingindo 80%. Em seguida, temos o método TOPSIS com 78%, SAW-AHP com 74% e SAW com 76%. [Firgiawan et al. \[2020\]](#)

Tabela 2: Resumo dos artigos selecionados - MCDM

Autores	Objetivo	Atributos	Atribuição de pesos	Método Classificação e Performance
Blasco-Blasco et al. [2021]	Avaliar performance dos alunos na Universidade de Santander, Colômbia	Estado económico, social, académico, cognitivo e de saúde	Não é necessário	uwTOPSIS, não é mencionada nenhuma métrica de avaliação
Wati et al. [2018]	Avaliar desempenho académico para futuras recomendações e avaliações do desempenho dos estudantes na Universidade Mulawarman	Género, idade, naturalidade e as notas dos alunos	Entropia e Ganho	MOORA e SMART com uma accuracy de 60,9% e uma precision de 53% para ambos os métodos
Sari et al. [2017]	Recrutamento de trabalhadores para a empresa Asia Exotica	Educação, experiência de trabalho, idade e estado civil	Atribuídos pela equipa de recursos humanos da própria empresa	AHP com uma accuracy de 80% a 90% quando comparado ao método manual
Bagi et al. [2020]	Identificar alunos com alto desempenho académico na escola SMP Negeri 11 Dumoga, Bolaang Mongondow District	Valor médio das notas, presença, atitude, atividades extra curriculares e cartas de recomendação	Atribuídos pelo comitê de seleção da universidade juntamente com AHP para calcular os pesos definitivos de cada critério	TOPSIS, nem a precision nem a accuracy são mencionadas neste artigo

Marbun et al. [2021]	Identificar alunos merecedores de bolsa de estudo em Universidades que fornecem bolsas de estudo do PPA concedidas pelo Ministério da Investigação, Tecnologia e Ensino Superior	Média das notas do aluno, número de créditos , atividades extra curriculares e rendimento familiar	Baseados nos requisitos estabelecido pelo Ministério da Pesquisa, Tecnologia e Ensino Superior	SAW, WP e TOPSIS, não é mencionado nem a precision nem a accuracy
Rianto et al. [2017]	Identificar alunos com maior compatibilidade para a área profissional escolhida disponibilizados pelo programa Diploma 3 Aeronautics STTA Yogyakarta	Competências académicas, domínio da língua inglesa, testes psicológicos, habilidades interpessoais (comunicação, resolução de problemas e pensamento crítico, gerência de tempo, cooperação e habilidades de adaptação) e atitudes	Atribuídos pelo comitê de seleção de estudantes universitários, chefes de departamentos e departamentos de cooperação juntamente com AHP para calcular os pesos definitivos de cada critério	TOPSIS com uma accuracy de 86,66% em comparação com a amostra real utilizada
Firgiawan et al. [2020]	Determinar o valor das propinas para estudantes com dificuldades financeiras na Universitas Sulawesi Barat, Indonésia	Rendimento familiar, condições de habitação e despesas	Atribuídos pelo Ministério da Educação e Cultura da República da Indonésia	SAW; TOPSIS; SAW-AHP; TOPSIS-AHP. Onde TOPSIS-AHP obteve uma accuracy de 80%, TOPSIS com 78%, SAW-AHP com 74% e SAW com 76%

Conforme é possível constatar pela revisão da literatura, os métodos escolhidos para atribuição de pesos e classificação das alternativas variam dependendo do objetivo do estudo, por exemplo, [Blasco-Blasco](#)

et al. [2021] e Wati et al. [2018] procuram medir e avaliar a performance de estudantes da universidade através de métodos robustos e estáveis que procuram contrariar a subjetividade característica do momento de atribuição de pesos, por outro lado, os restantes estudos baseavam os pesos atribuídos aos dados utilizados em comités ou outras entidades competentes capazes de determinar a importância dos mesmos.

Relativamente aos dados utilizados, e conforme a conclusão retirada após a análise da Tabela 2, mesmo quando os estudos compartilham objetivos, o conjunto de atributos varia, não sendo portanto adequado indicar que há um único conjunto certo a ser utilizado.

Assim, o melhor método depende das características específicas do problema e das preferências do *decision maker*, não sendo adequado indicar que há uma única técnica certa de *MCDM* a ser aplicada para um sistema de apoio a decisão. No entanto, o método mais utilizado nos artigos revistos foi o TOPSIS como método principal de classificação de alternativas, ou um método híbrido, como TOPSIS-AHP, sendo que este último foi o que apresentou maior *accuracy* em relação aos restantes estudos. Contudo, pode-se concluir que os métodos *MCDM* em geral, oferecem boa *accuracy* com uma média de 75% num intervalo entre 53% e 90%.

2.3 Multi-Criteria Decision Making Methods

Multi-Criteria Decision Making Methods é um dos principais problemas de tomada de decisão que visa determinar a melhor alternativa considerando mais de um critério no processo de seleção. Estes métodos consideram diferentes critérios qualitativos e quantitativos que precisam de ser fixos para encontrar a melhor solução Taherdoost and Madanchian [2023].

Em Mohsin [2018] *MCDM* é definido como "uma extensão da teoria da decisão que cobre qualquer decisão com múltiplos objetivos". Mohsin [2018] define ainda *MCDM* como "um termo abrangente para descrever uma coleção de abordagens formais, que buscam levar em consideração vários critérios explícitos para ajudar indivíduos ou grupos a explorar decisões importantes". No fundo, o objetivo de *MCDM* é auxiliar os *decision makers* a tomar decisões de preferência sobre as alternativas disponíveis que são caracterizadas por atributos múltiplos, geralmente conflitantes.

A tomada de decisão multi-critério, normalmente inclui três etapas principais, conforme é possível observar na Figura 4: Identificar e selecionar os critérios, determinar os pesos das alternativas e classificar as alternativas.

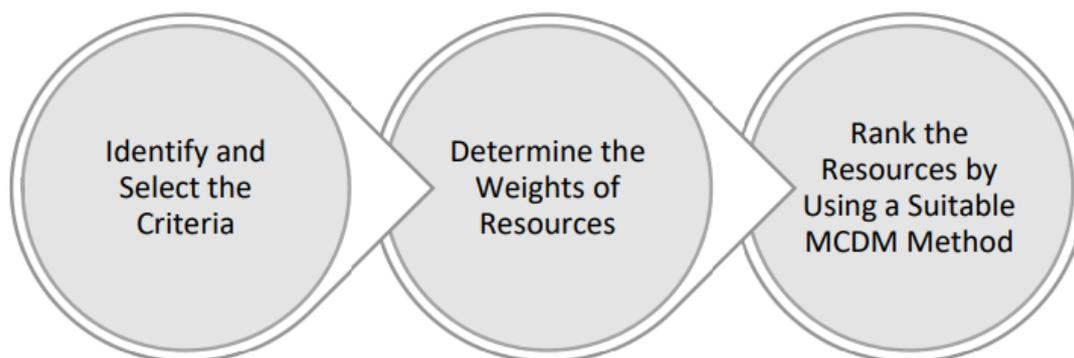


Figura 4: Etapas de MCDM [Taherdoost and Madanchian \[2023\]](#)

A primeira etapa consiste na identificação dos critérios relevantes que devem ser considerados no processo de tomada de decisão, geralmente isto é feito pelos *decision makers*. Esses critérios podem ser qualitativos ou quantitativos e variam consoante os problemas, podendo incluir considerações econômicas, ambientais, sociais, entre outras.

Na segunda etapa, os pesos ou prioridades são atribuídas a cada critério para refletir sua importância relativa ao problema em questão. Esses pesos podem ser determinados por meio de julgamento subjetivo por parte dos *decision makers* ou usando técnicas matemáticas como o Analytic Hierarchy Process (AHP) ou o Analytic Network Process (ANP), entre outros.

Por fim, os resultados da avaliação para cada alternativa e critério são agregados para obter uma classificação geral ou pontuação para cada alternativa.

Relativamente à segunda e terceira etapa, existem vários métodos e diferentes técnicas de MCDM que podem ser utilizadas, conforme foi falado na revisão da literatura. Métodos como SAW, WP, TOPSIS, AHP, SMART e MOORA podem ser utilizados, cada um com vantagens e desvantagens.

Sumariando, as técnicas de *MCDM* fornecem uma abordagem sistemática e transparente para a tomada de decisão, facilitando uma consideração mais abrangente de vários critérios e ajudando os *decision makers* a selecionar a alternativa mais adequada com base nas suas preferências e objetivos.

2.3.1 Métodos de atribuição de pesos

AHP

Analytic Hierarchy Process reflete o comportamento natural do pensamento humano, resolvendo problemas complexos decompondo-os numa hierarquia de subproblemas mais facilmente compreendidos, tendo o objetivo geral no topo, os critérios no meio, e as alternativas nos níveis mais baixos [Mohsin \[2018\]](#).

Uma característica distinta do método AHP é a utilização de comparações pareadas, que servem para avaliar várias alternativas em relação a diferentes critérios e estimar os seus pesos. Este método depende dos julgamentos de especialistas para desenvolver escalas de prioridade e obter pesos, frequentemente expressos numericamente, para indicar a importância relativa ou a preferência entre os elementos avaliados. Os pesos dos critérios são derivados matematicamente com base nos julgamentos fornecidos.

Em suma, este método oferece uma abordagem sistemática e estruturada para auxiliar os *decision makers* a quantificar os seus julgamentos, resultando em pesos e classificações significativas para critérios e alternativas.

Relativamente aos passos que devem ser considerados para a implementação do método AHP e de acordo com [Ariff et al. \[2008\]](#) temos que:

1. Definir o problema
2. Estabelecer a hierarquia
3. Comparação em pares
4. Construir a matriz de confusão
5. Normalizar a matriz
6. Calcular os pesos dos critérios
7. Verificar a consistência
8. Determinar a importância geral
9. Tomar a decisão

A implementação do método AHP envolve várias etapas essenciais, desde a definição do problema até a classificação das alternativas. A definição da hierarquia desempenha um papel central nesse processo, proporcionando uma estrutura que facilita a compreensão e organização do problema em questão.

Na hierarquia, o primeiro nível apresenta o objetivo da decisão, enquanto o segundo nível identifica os principais critérios que influenciam o domínio do problema. À medida que surgem subcritérios, níveis adicionais podem ser necessários para a sua caracterização. No nível mais baixo da hierarquia, são identificadas as alternativas, que representam as opções de decisão disponíveis.

Em seguida, é construída a matriz de comparações pareadas, que reflete as classificações relativas para cada nível da hierarquia. Os valores relativos atribuídos são baseados na experiência e no conhecimento dos *decision makers*. Geralmente, a escala de Saaty, uma escala de nove pontos, é usada para

avaliar a importância relativa ou intensidade entre os critérios. Essa escala permite que os *decision makers* incorporem o seu conhecimento de forma intuitiva no processo de comparação.

Essa versão mais concisa mantém a essência das informações importantes sobre o processo do método AHP, tornando-o mais fácil de ler e compreender em um contexto acadêmico.

Relative intensity	Definition	Explanation
1	Equal value	Two requirements are of equal value
3	Slightly more value	Experience slightly favours one requirement over another
5	Essential or strong value	Experience strongly favours one requirement over another
7	Very strong value	A requirement is strongly favoured and its dominance is demonstrated in practice
9	Extreme value	The evidence favouring one over another is of the highest possible order of affirmation
2, 4, 6, 8	Intermediate values between two adjacent judgements	When compromise is needed

Figura 5: Escala Saaty Ariff et al. [2008]

Para a normalização da matriz de comparações é utilizada a seguinte equação:

$$rij = \frac{xij}{\sum_{j=1}^m xij} \quad (2.1)$$

Onde rij representa o valor normalizado, xij o valor inicial na matriz de comparações pareadas antes da normalização.

O cálculo efetuado na sexta etapa é reproduzido pela seguinte equação:

$$wj = \frac{\sum_{i=1}^m rij}{m} \quad (2.2)$$

Onde wj representa o valor do peso do critério e rij o valor normalizado calculado na equação 2.1 .

Para a etapa de verificação da consistência seguem-se múltiplas sub etapas, sendo estas as seguintes:

1. Multiplicação da matriz de comparação pareadas pelo respectivo vetor de pesos
2. Soma dos valores de cada critério
3. Divisão do valor pelo respectivo peso do critério
4. Cálculo do lambda máximo, que consiste na media dos valores anteriormente calculados

Matrix size	Random consistency index (RI)
1	0.00
2	0.00
3	0.58
4	0.90
5	1.12
6	1.24
7	1.32
8	1.41
9	1.45
10	1.49

Figura 6: Random Index Saaty [Ammarapala et al. \[2018\]](#)

5. Cálculo do índice de consistência (CI), conforme a Equação 2.3
6. Cálculo da taxa de consistência (CR), que consiste na divisão do CI pelo *Random Index (RI)* apresentado na Figura 6
7. Análise dos resultados

$$CI = \frac{(\lambda_{max} - n)}{n - 1} \quad (2.3)$$

Após o cálculo da consistência e a análise da taxa de consistência (CR), é possível tirar uma conclusão sobre a consistência dos pesos atribuídos. Se o valor de CR for menor que 0.1, o vetor de pesos calculado nas etapas anteriores pode ser considerado válido e utilizado como pesos dos critérios na tomada de decisão. No entanto, se o valor de CR for maior ou igual a 0.1, a matriz de pesos é considerada inconsistente e requer revisão.

Vantagens

O AHP é uma ferramenta analítica altamente flexível e poderosa, capaz de lidar com uma ampla variedade de problemas, sejam eles qualitativos ou quantitativos, o que o torna versátil em diferentes contextos. [Rianto et al. \[2017\]](#) A sua facilidade de uso torna-o acessível a um amplo espectro de *decision makers*, independentemente de sua experiência.

Uma característica crucial deste método é a capacidade de capturar medidas de avaliação tanto subjetivas quanto objetivas, tornando-o adaptável a situações diversas. Além disso, o método inclui um mecanismo para verificar e controlar inconsistências nas decisões, garantindo resultados mais confiáveis e robustos. [Tsesmelis et al. \[2019\]](#)

Desvantagens

Apesar das múltiplas vantagens do método AHP, ele apresenta algumas limitações, sendo uma das principais limitações relacionada ao consumo de tempo e à eficiência do processo. Isto ocorre devido ao grande número de comparações pareadas necessárias, o que implica cálculos matemáticos que aumentam à medida que o número de atributos e alternativas cresce ou se modifica. Este aspecto torna o AHP menos eficaz em problemas mais complexos.

Além disso, é importante notar que as pontuações e classificações no AHP dependem das alternativas que são consideradas para avaliação. Isso significa que a escolha das alternativas pode influenciar os resultados finais [Mohsin \[2018\]](#).

Devido à limitação de eficiência relacionada ao número de comparações, muitas vezes é necessário recorrer a outros métodos para classificar alternativas de forma mais eficaz. Um exemplo amplamente estudado é o AHP-TOPSIS, conforme ilustrado na Tabela 2.

SAW

O método **Simple Additive Weighting** também frequentemente conhecido como o weighted sum method (WSM), é um método de tomada de decisão multi-critério usado para classificar um conjunto de alternativas com base no seu desempenho em um conjunto de critérios. O método foi introduzido pela primeira vez por Yoon e Hwang em 1981. [Marbun et al. \[2021\]](#) A ideia base do SAW é representar cada alternativa como um vetor de desempenho em cada critério e, em seguida, ponderar e somar os critérios para obter uma pontuação geral para cada alternativa. Para fazer isso, o método envolve as seguintes etapas:

1. Definir o problema
2. Determinar o peso ou nível de importância de cada critério
3. Construir a matriz de decisão
4. Normalizar a matriz de decisão
5. Calcular a matriz normalizada com os pesos
6. Calcular o score total das alternativas
7. Tomar a decisão

O método SAW, semelhante ao AHP, começa com a definição clara do problema e a atribuição subjetiva de pesos aos critérios a serem analisados. É importante observar que, durante a atribuição de pesos, a soma total desses pesos deve ser igual a 1, refletindo sua importância relativa.

Uma vez que a matriz de confusão tenha sido construída, incluindo as alternativas em relação aos critérios, o próximo passo é normalizá-la. A fórmula a seguir é usada para a normalização:

$$rij = \begin{cases} \frac{xij}{Max.xij} \\ \frac{Min.xij}{xij} \end{cases} \quad (2.4)$$

A normalização é uma etapa crítica para garantir que os valores estão numa escala comparável, facilitando a análise e a tomada de decisão.

Aqui Rij corresponde ao valor normalizado e xij ao valor inicial da matriz de confusão antes da normalização. Existem duas equações sendo que a equação a ser utilizada depende do impacto do critério no problema, caso o critério seja de custo então a função a ser utilizada é a de minimização, caso contrário a equação a ser utilizada é a de maximização.

De seguida é calculada a matriz normalizada com os pesos atribuídos aos critérios, tal e feito através da equação seguinte:

$$Vi = \sum_{j=1}^n Wj.rij \quad (2.5)$$

O resultado final do valor da preferência é obtido a partir da soma dos valores calculados através da equação 2.5. Por fim, podemos tomar uma decisão através dos resultados obtidos, uma vez que um valor de preferência maior indica que a alternativa é a melhor alternativa.

Vantagens

O método SAW apresenta várias vantagens notáveis. Um dos principais benefícios é a simplicidade do cálculo no processo, tornando-o altamente eficiente em termos de tempo de execução em comparação com outros métodos de tomada de decisão multi critério. Além disso, SAW é conhecido por ser intuitivo para os decisores, facilitando a compreensão e a aplicação do método [Anggraini and Sihotang \[2019\]](#)

Além disso, o SAW tem a capacidade de realizar julgamentos com maior precisão, uma vez que se baseia em valores pré-definidos e pesos de preferência. Essa abordagem ajuda a quantificar as preferências e os critérios de maneira mais precisa, contribuindo para resultados mais confiáveis na tomada de decisão. [Wira Trise Putra, Dede and Agustian Punggara, Adrian \[2018\]](#)

Desvantagens

Mohsin [2018]

O método SAW também apresenta desvantagens, pois não tende a refletir completamente a situação real e requer que todos os valores dos critérios sejam positivos e máximos.

EWM

O método **Entropy Weight** é um modelo amplamente estudado e aplicado de atribuição de pesos devido à sua objetividade na ponderação de atributos. O EWM é especialmente útil para estabelecer pesos objetivos dos atributos, determinando a importância de cada um deles sem considerar preferências pessoais dos decisores.

A entropia, neste contexto, é uma medida de incerteza que quantifica a quantidade média de informação necessária para representar um evento.

O uso do EWM envolve o cálculo da entropia de cada subcritério, que é então utilizado como peso para os mesmos. Isso permite uma atribuição objetiva de pesos aos atributos, independentemente das preferências individuais, garantindo uma abordagem imparcial e informada na tomada de decisão.

Este método inclui 5 etapas de acordo com Kumar et al. [2021], para calcular os pesos objetivos:

1. Definir o problema
2. Determinar critérios e alternativas
3. Construir a matriz de decisão
4. Normalizar a matriz de confusão
5. Cálculo da entropia para cada critério
6. Cálculo dos pesos de cada critério

O método EWM, semelhante aos métodos anteriores, começa com a definição do problema. No entanto, o que o distingue é a ausência de uma atribuição subjetiva de pesos aos critérios. Em vez disso, após a construção da matriz de decisão e sua subsequente normalização, como representado na fórmula da Equação 2.8, é realizado o cálculo da entropia para cada critério do problema. Esse cálculo é realizado da seguinte maneira:

$$e_i = -c \sum_{j=1}^{yr} p_{ij} \cdot \ln p_{ij} \quad (2.6)$$

Onde c é dado por :

$$c = \frac{1}{\ln yr} \quad (2.7)$$

Uma vez calculada a entropia de cada atributo é então calculado o seu respetivo peso tendo por base a Equação 2.13. Por fim, este método pode ser aplicado em conjunto com outro método, para que seja feito o ranking das alternativas.

$$p_{ik} = \frac{y_{ik}}{\sum_{j=1}^{yr} y_{ij}} (1 \leq j \leq m, 1 \leq k \leq yr) \quad (2.8)$$

$$a_i = \frac{1 - e_i}{m - \sum_{i=1}^m e_i} \quad (2.9)$$

Vantagens

Comparado a vários modelos subjetivos de ponderação, a maior vantagem do EWM é a sua capacidade de evitar a interferência de fatores humanos na atribuição de pesos aos indicadores, resultando em uma avaliação mais objetiva e imparcial. Devido a essa característica, o EWM tem sido amplamente adotado na tomada de decisões nos últimos anos. [Ding et al. \[2017\]](#).

Além disso, o EWM destaca-se pela sua capacidade de detetar o impacto fraco de atributos incomuns, aprimorando gradualmente a precisão e o bom senso dos resultados da avaliação.

Por fim, o método é eficaz na manipulação de grandes conjuntos de dados com vários critérios. Ele oferece uma abordagem escalável que pode ser aplicada a problemas de decisão complexos com múltiplos critérios, permitindo que os *decision makers* lidem com uma ampla variedade de cenários de forma eficaz [Tsesmelis et al. \[2019\]](#).

Desvantagens

Apesar da objetividade inerente ao sistema, que é uma grande vantagem, também pode ser vista como uma desvantagem, pois não permite a participação do *decision maker* e baseia-se exclusivamente na entropia para atribuir pesos. Isso significa que a perspectiva e as preferências dos decisores não são consideradas, o que pode ser limitante em certos contextos.

Além disso, o EWM é sensível à distribuição de dados de cada critério. Ele pressupõe que os critérios seguem uma distribuição de probabilidade e, desvios dessa suposição, podem afetar a precisão dos pesos atribuídos. Se a distribuição de dados não se conformar com as suposições subjacentes, os pesos resultantes podem não refletir com precisão a importância relativa dos critérios.

Outra limitação é que o método pode atribuir um peso alto a critérios que podem ser considerados não importantes. Isso ocorre porque o EWM dá igual ênfase a todos os critérios em termos dos seus valores de entropia. Em alguns casos, certos critérios podem ter baixa entropia devido à sua variabilidade limitada, mas ainda podem ser altamente relevantes para o problema de decisão. Assim, o EWM pode não capturar completamente o verdadeiro significado de tais critérios, potencialmente resultando abaixo do ideal [Tsesmelis et al. \[2019\]](#).

WP

O método Weighted Product (WP) é uma técnica de tomada de decisão multi-critério que visa classificar um conjunto de alternativas com base no seu desempenho em um conjunto de critérios. Este método foi introduzido pela primeira vez por Yoon em 1987 e diferencia-se do Weighted Sum (WS) principalmente na operação matemática utilizada: adição no WS e multiplicação no WP [Mohsin \[2018\]](#).

A ideia principal do WP é representar cada alternativa como um vetor do seu desempenho em cada critério e, em seguida, ponderar e multiplicar os critérios para obter uma pontuação geral para cada alternativa. Para fazer isso, o método envolve as seguintes etapas:

1. Definir o problema
2. Atribuir pesos aos critérios
3. Construir matriz de decisão
4. Normalizar matriz de decisão
5. Determinar os valores do vetor S (vetor peso)
6. Determinar os valores do vetor V (score total das alternativas)

Tal como no método SAW, as três primeiras etapas mantêm-se intactas, onde consiste na definição do problema, atribuição subjetiva dos pesos dos atributos e a construção da respetiva matriz de decisão. A soma total dos pesos deve dar um valor igual a 1. A nível da normalização dos valores, esta é feita com base numa das seguintes expressões:

$$n_{ij} = \frac{x_{ij}}{\sum_{i=1}^m x_{ij}} \quad (2.10)$$

Caso seja um critério de benefício.

$$n_{ij} = \frac{\frac{1}{x_{ij}}}{\sum_{i=1}^m \frac{1}{x_{ij}}} \quad (2.11)$$

Caso seja um critério de custo.

Conforme o impacto dos atributos no problema, a equação de normalização de benefício ou custo deve ser utilizada.

Após feita a normalização, deve ser calculado o vetor dos pesos, com base na operação de multiplicação observada abaixo:

$$s_i \prod_{j=1}^n x_{ij}^{w_j} \quad (2.12)$$

Onde w_j corresponde ao valor do peso atribuído ao critério j e x_{ij} é o valor da alternativa i sobre o critério j .

Depois de obter o vetor S , determina-se o vetor de preferência de cada alternativa. Os valores vetoriais são obtidos a partir dos resultados de cada pontuação alternativa divididos pela pontuação total, de acordo com a equação seguinte:

$$v_i = \frac{\prod_{j=1}^n x_{ij}^{w_j}}{\prod_{j=1}^n (x_{ij}^*)^{w_j}} \quad (2.13)$$

O vetor V é uma representação das preferências alternativas e é usado para classificar cada alternativa com base nos valores do vetor S , que são obtidos multiplicando os valores de desempenho de cada alternativa pelos pesos atribuídos aos critérios. Para calcular o vetor V , somam-se todos os valores do vetor S .

Em última análise, podemos tomar uma decisão com base nos resultados obtidos no vetor V . Um valor de preferência mais alto indicará que a alternativa é a melhor escolha, uma vez que reflete um desempenho superior em relação aos critérios ponderados.

Vantagens

O WP é frequentemente chamado de 'análise adimensional' devido à sua estrutura que elimina unidades de medida, tornando-o uma ferramenta versátil para lidar com problemas de tomada de decisão tanto unidimensionais quanto multidimensionais. Essa característica é uma vantagem notável do método, pois

permite que ele seja aplicado a uma ampla variedade de contextos, independentemente das unidades de medida envolvidas.

Além disso, o WP tem a capacidade de usar valores relativos em vez de valores absolutos, o que é útil quando se deseja considerar o desempenho relativo das alternativas em relação aos critérios. Isso amplia ainda mais sua utilidade em situações em que as medidas absolutas podem não ser tão relevantes [Triantaphyllou et al. \[1998\]](#).

Wp tem ainda como vantagem o facto de ser simples de executar, o que o torna acessível. Além disso, sua abordagem é fácil de entender pelo público em geral, tornando-o uma ferramenta de tomada de decisão acessível. Uma vantagem adicional é que o WP não envolve etapas arbitrárias, o que significa que suas etapas de cálculo são baseadas em princípios matemáticos claros. Isso contribui para a objetividade do método, garantindo que os resultados sejam fundamentados em critérios transparentes e consistentes

Desvantagens

Apesar das vantagens do WP, ele apresenta algumas limitações importantes a serem consideradas. Primeiramente, o método depende significativamente da subjetividade dos *decision makers* ao atribuir pesos aos critérios. Essa atribuição subjetiva pode introduzir viés nos resultados, pois as preferências individuais podem variar.

Outra limitação é que o WP é altamente sensível aos pesos atribuídos aos critérios. Pequenas variações nos pesos podem levar a resultados significativamente diferentes, o que pode ser problemático em cenários onde a atribuição de pesos não é precisa. [Setyawan et al. \[2017\]](#)

Além disso, o WP assume uma relação linear entre os critérios, o que significa que não considera relações não lineares complexas entre eles. Se houver interações ou dependências não lineares entre os critérios, o WP pode não capturar com precisão essas dinâmicas, levando a decisões sub ótimas.

2.3.2 Métodos para classificação de alternativas

TOPSIS e uwTOPSIS

Technique for Order Preference by Similarity to Ideal Solution é um método de critérios múltiplos que ajuda a escolher a melhor alternativa a partir de um conjunto limitado de opções. Essa escolha é baseada em dois princípios: minimizar a distância em relação a uma solução ideal e maximizar a distância em relação a uma solução não ideal, como discutido por [Olson \[2004\]](#). Em termos simples, o objetivo é encontrar uma alternativa que esteja mais próxima da solução ideal positiva, ao mesmo tempo em que está

o mais distante possível da solução ideal negativa. Soluções ideais positivas são aquelas que maximizam os critérios de benefício e minimizam os critérios de custo, enquanto as soluções ideais negativas fazem o contrário, maximizando os critérios de custo e minimizando os critérios de benefício, como explicado por outro estudo [Rianto et al. \[2017\]](#).

O método (TOPSIS) é particularmente relevante em problemas que envolvem alternativas discretas e dados objetivos. A sua utilidade destaca-se, especialmente em situações com um grande número de alternativas e atributos a serem considerados. Isso o torna uma das ferramentas mais práticas para a resolução de problemas do mundo real.

O método TOPSIS oferece uma abordagem para avaliar várias alternativas, comparando cada alternativa com a melhor e a pior opção disponível. Essa comparação classifica as alternativas com base na sua proximidade em relação aos extremos do espectro.

Uma vez que as alternativas tenham sido classificadas, essas classificações podem servir como um guia para os *decision makers* na escolha da melhor solução. O apelo deste método reside na sua simplicidade conceitual, facilidade de compreensão, eficiência computacional e capacidade de medir o desempenho relativo das opções de decisão.

O método TOPSIS é amplamente utilizado na prática da tomada de decisão, tornando-se uma ferramenta valiosa para resolver uma variedade de problemas do mundo real. A seguir, descrevemos as etapas fundamentais desse método [Triantaphyllou et al. \[1998\]](#)[Li et al. \[2011\]](#) [Liern and Gladish \[2022\]](#).

1. Definir o problema
2. Estruturar a matriz de decisão
3. Determinar os impactos e os pesos dos atributos
4. Normalizar a matriz de decisão
5. Calcular a matriz de decisão com os pesos
6. Determinar as soluções ideais e as soluções ideais negativas
7. Calcular a distancia das alternativas
8. Calcular a Proximidade Relativa da Solução Ideal
9. Classificar a ordem de preferência das alternativas

No método TOPSIS, após a definição e estruturação do problema, o próximo passo envolve a atribuição de pesos e a avaliação do impacto de cada atributo no problema. Esses pesos podem ser determinados usando métodos de atribuição de pesos objetivos ou podem ser atribuídos subjetivamente, levando em consideração a perspectiva dos *decision makers*. É importante ressaltar que a soma total dos pesos deve ser igual a 1, garantindo que todos os atributos sejam devidamente considerados.

Em seguida, é construída a matriz de decisão, que contém as informações sobre as alternativas e seus atributos. Essa matriz é normalizada, seguindo a seguinte equação:

$$R_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}} \quad (2.14)$$

Esta normalização é um passo essencial para garantir que as diferenças nas escalas de medida dos atributos não influenciem negativamente o processo de tomada de decisão. O método TOPSIS leva em consideração a importância relativa dos atributos, permitindo uma avaliação mais precisa das alternativas disponíveis.

Em seguida, a matriz resultante é calculada, levando em consideração os pesos atribuídos. Isso é feito multiplicando a matriz original pelos respectivos pesos dos atributos.

Para determinar as soluções ideais e não ideais, são utilizadas as seguintes expressões:

$$S^+ = (y_1^+, y_2^+, y_3^+, \dots, y_n^+) \quad (2.15)$$

$$S^- = (y_1^-, y_2^-, y_3^-, \dots, y_n^-) \quad (2.16)$$

Para calcular a distância as soluções ideais de cada alternativa é usada a equação:

$$D_i^+ = \sqrt{\sum_{j=1}^n (y_{ij} - y_j^+)^2}, i = 1, 2, 3, \dots, m \quad (2.17)$$

$$D_i^- = \sqrt{\sum_{j=1}^n (y_{ij} - y_j^-)^2}, i = 1, 2, 3, \dots, m \quad (2.18)$$

Por fim, é calculada a proximidade de cada alternativa em relação à solução ideal, conforme representado na Equação 2.28. Após calcular as distâncias de todas as alternativas em relação às soluções ideais, a alternativa que apresenta maior proximidade é considerada a melhor escolha, e aquela com menor proximidade é classificada como menos desejável. Este processo torna a seleção da melhor alternativa um procedimento objetivo e eficaz.

$$V_i = \frac{D_i^-}{D_i^- + D_i^+}, i = 1, 2, 3, \dots, m \quad (2.19)$$

Vantagens

O método TOPSIS apresenta várias vantagens significativas. Primeiramente, sua facilidade de aplicação torna-o acessível e prático para a tomada de decisões. Além disso, o método é eficaz na identificação rápida da melhor alternativa, agilizando o processo de seleção. A lógica por detrás deste método é intuitiva e clara, reflete o raciocínio típico da escolha humana, tornando os resultados facilmente compreensíveis.

Outra das vantagens do TOPSIS é a sua flexibilidade em relação aos pesos dos critérios. Os pesos podem ser expressos de diversas maneiras: quantitativos, qualitativos ou relativos, e podem variar em termos de precisão e certeza. Além disso, esses pesos podem ser determinados de forma objetiva, com base em dados concretos, ou de forma subjetiva, levando em consideração a opinião de um ou mais *decision makers*. Isso torna o TOPSIS uma abordagem versátil e adaptável para uma ampla gama de situações de tomada de decisão.

Outra vantagem notável é a sua eficiência computacional. Essas características garantem que o método possa ser aplicado de forma eficaz em várias situações práticas. Além disso, o TOPSIS oferece a capacidade de medir o desempenho relativo de cada alternativa de maneira simples e matemática, facilitando a análise objetiva.

Por último, o método TOPSIS também oferece a possibilidade de visualização, permitindo aos *decision makers* uma representação gráfica que pode ser valiosa na compreensão e comunicação dos resultados [Roszkowska \[2011\]](#).

Desvantagens

O método TOPSIS apresenta, no entanto, algumas desvantagens. Duas das principais preocupações incluem a possibilidade de correlações entre critérios e a subjetividade associada à atribuição de pesos a esses critérios. A aplicação da Distância Euclidiana no TOPSIS não considera a correlação entre os atributos, o que pode ser uma limitação em cenários onde essas relações são importantes.

Outra desvantagem associada ao TOPSIS é a ocorrência de inversão na classificação. Isso ocorre quando a ordem de preferência das alternativas muda devido à adição ou remoção de uma alternativa no problema de decisão. Essa inversão pode ser problemática em muitos casos, uma vez que a estabilidade das classificações é essencial para a tomada de decisões confiáveis [Galik et al. \[2022\]](#).

uwTOPSIS

A abordagem clássica do TOPSIS envolve a ordenação de alternativas com base na distância relativa em relação à solução ideal. Quanto mais próximo o resultado dessa métrica estiver de 1, melhor é a posição da alternativa na classificação. No entanto, o método tradicional do TOPSIS é frequentemente subjetivo, uma vez que os pesos dos critérios são atribuídos por entidades individuais, tornando-o sensível a essa atribuição.

Uma solução para esse problema é apresentada em [Liern and Gladish \[2022\]](#), onde é proposto o método unweighted TOPSIS (uwTOPSIS). Nesse método, os valores dos pesos não são estabelecidos a priori, mas tratados como variáveis de decisão a serem otimizadas para maximizar a proximidade relativa de cada alternativa em relação à solução ideal. A única informação a priori utilizada sobre os pesos são os limites superior e inferior dos valores, fornecidos pelos *decision makers*, que são incorporados como restrições no problema. O resultado final é um novo índice de proximidade relativa que depende dos valores dos pesos.

Essa abordagem visa eliminar a subjetividade na atribuição de pesos aos critérios, mantendo as vantagens do método tradicional. No entanto, uma desvantagem notável é que o uwTOPSIS atribui igual importância a todos os critérios, o que nem sempre reflete as preferências dos *decision makers* ou a importância relativa dos critérios em um problema de decisão do mundo real.

As etapas do uwTOPSIS são semelhantes às do TOPSIS tradicional, exceto pela atribuição dos pesos e alguns ajustes específicos. As etapas fundamentais são as seguintes [Liern and Gladish \[2022\]](#):

1. Definir o problema
2. Estruturar a matriz de decisão
3. Normalizar a matriz de decisão
4. Determinar as soluções ideais e as soluções ideais negativas
5. Definir duas funções para calcular as distâncias à solução ideal e não ideal
6. Calcular a função de proximidade relativa à solução ideal
7. Calcular os intervalos de proximidade relativa à solução ideal
8. Classificar os intervalos

MOORA

Multi-Objective Optimization based on Ration Analysis, também conhecido como otimização multi-critério ou otimização de múltiplos atributos, foi introduzido por Brauers em 2004. Este método é uma técnica poderosa para a otimização de múltiplos objetivos, e tem se mostrado eficaz na resolução de uma variedade de problemas complexos de tomada de decisão [Aan et al. \[2017\]](#).

O MOORA permite que os *decision makers* considerem vários critérios, cada um com escalas e preferências de medida diferentes. Isso auxilia na seleção da alternativa mais favorável, com base nos critérios fornecidos e OS seus pesos relativos. Este método é especialmente útil quando os critérios são de natureza conflituante, ou seja, alguns têm natureza benéfica, onde valores mais altos são desejáveis, enquanto outros têm natureza não benéfica.

Este, opera através da conversão sistemática dos valores dos critérios em razões e, em seguida, realiza uma análise de razão para determinar as classificações das alternativas a partir de um conjunto de opções viáveis disponíveis. Este método fornece uma abordagem estruturada e eficaz para lidar com problemas complexos de tomada de decisão, permitindo a comparação de alternativas de maneira objetiva e eficiente [Wati et al. \[2018\]](#).

No processo de atribuição de pesos aos critérios, o método MOORA pode ser combinado com outras técnicas, como o AHP ou a análise de entropia e ganho, como mencionado em [Wati et al. \[2018\]](#) e [Aan et al. \[2017\]](#). O uso do ganho, em particular, é uma abordagem onde a entropia é utilizada para determinar a importância relativa dos critérios em relação aos pesos. Quanto maior o ganho associado a um critério, maior a sua importância.

De seguida são apresentadas as etapas do método MOORA [Aan et al. \[2017\]](#):

1. Definir o problema
2. Estruturar a matriz de decisão
3. Normalizar a matriz de decisão
4. Atribuir os pesos e impactos aos atributos
5. Calcular os valores ponderados
6. Classificar as alternativas

As etapas iniciais do método MOORA são paralelas às do TOPSIS. Começam com a definição do problema e dos critérios relevantes, seguida pela construção da matriz de decisão e a atribuição de pesos

aos critérios. Essa atribuição de pesos pode ser realizada com base em outros métodos ou subjetivamente, e os pesos devem somar 1 no total, como no TOPSIS.

Além disso, o método de normalização da matriz no MOORA é semelhante ao utilizado no TOPSIS e pode ser visto na Equação 2.14.

A diferença entre métodos envolve o cálculo dos valores dos atributos com base nos pesos e os seus respectivos impactos. Assim, esses cálculos são realizados com base na seguinte expressão:

$$y_i = \sum_{j=1}^g w_j x_{ij}^* - \sum_{j=g+1}^n w_j x_{ij}^* (j = 1, 2, \dots, n) \quad (2.20)$$

Vantagens

O método MOORA é notável pela sua simplicidade computacional, fácil compreensão e robustez. Baseia-se em cálculos matemáticos simples, que resultam num baixo tempo computacional, conforme evidenciado em Wati et al. [2018]. Além disso, uma grande vantagem deste método é que o seu procedimento de cálculo não é afetado pela introdução de parâmetros adicionais. Portanto, o método MOORA é altamente estável e pode ser aplicado a uma variedade de problemas de tomada de decisão, como mencionado em Chakraborty [2011].

Uma das principais vantagens do MOORA é sua capacidade de considerar todos os atributos, bem como as suas importâncias relativas. Isso possibilita uma avaliação mais precisa das alternativas. Além disso, o MOORA é flexível, permitindo a consideração de qualquer número de atributos, sejam eles quantitativos ou qualitativos. Ele fornece uma abordagem de seleção objetiva e lógica para tomada de decisão, conforme destacado em Chakraborty [2011].

Desvantagens

Similar a muitos dos métodos discutidos até agora, o método MOORA também apresenta desvantagens significativas. Uma delas é a subjetividade associada à atribuição de pesos aos critérios, o que pode afetar a objetividade do processo decisório.

Além disso, o MOORA baseia-se na análise de razão para determinar as classificações das alternativas. Embora seja uma abordagem simples e direta, pode não ser capaz de capturar toda a complexidade dos problemas de decisão que envolvem critérios e interações altamente diversificados.

Outra desvantagem a ser considerada é que a eficiência do método MOORA tende a diminuir à medida que a matriz de decisão se torna maior, o que pode limitar sua aplicabilidade em cenários com um grande número de alternativas e critérios.

Essas desvantagens destacam as limitações do MOORA em cenários nos quais a objetividade, a complexidade e a escalabilidade são preocupações importantes na tomada de decisão.

PROMETHEE

O método Preference Ranking Organization Methods for Enrichment Evaluations (PROMETHEE) foi desenvolvido com base no conceito de relações de superação proposto por J.P. Brans em 1982. Este método é amplamente utilizado por *decision makers* e analistas em todo o mundo e desempenha um papel fundamental na pesquisa acadêmica para aprimorar a tomada de decisões em diversas áreas.

O PROMETHEE foi criado como uma alternativa mais simples ao método ELECTRE e baseia-se no uso de funções de preferência para modelar os julgamentos e preferências dos *decision makers*. A família PROMETHEE inclui diferentes métodos adequados para diferentes situações de decisão, com PROMETHEE I, PROMETHEE II, PROMETHEE III (ordem de intervalo) e PROMETHEE IV (para um conjunto contínuo de alternativas) entre as suas variantes [Mota \[2013\]](#).

O PROMETHEE fornece uma abordagem transparente e sistemática para a tomada de decisões, considerando aspetos positivos e negativos das alternativas. Ele permite que os *decision makers* expressem as suas preferências por meio de comparações pareadas, facilitando a análise de problemas complexos com múltiplos critérios. Isso ajuda na seleção da alternativa mais apropriada, com base nas preferências e pesos atribuídos pelo *decision maker* [Rafi et al. \[2020\]](#).

1. Definir o problema
2. Determinar os pesos e o impacto dos critérios
3. Construir e normalizar a matriz de decisão
4. Comparar as alternativas em pares
5. Determinar as funções de preferência
6. Calcular as funções de preferência para cada critério
7. Determinar os índices de preferência para cada combinação de alternativa e critério
8. Determinar os *outranking flows*
9. Calcular o *net flow*
10. Classificar as alternativas

Após a definição do problema e a atribuição dos pesos aos critérios, onde a soma total dos pesos é igual a 1, o método PROMETHEE procede à normalização da matriz de decisão. Isso é feito usando as seguintes equações, levando em consideração o impacto de cada critério:

$$R_{ij} = \frac{[D_{ij} - \min D_{ij}]}{[\max(D_{ij}) - \min(D_{ij})]} \quad (2.21)$$

$$R_{ij} = \frac{[\max D_{ij} - D_{ij}]}{[\max(D_{ij}) - \min(D_{ij})]} \quad (2.22)$$

Essa normalização é crucial para garantir que os diferentes critérios, com pesos variados, sejam tratados de maneira equitativa ao comparar as alternativas durante o processo de tomada de decisão. Ela permite que o método leve em consideração as diferenças nas escalas e unidades de medida dos critérios, proporcionando uma análise mais justa e precisa das alternativas.

As funções de preferência são determinadas de acordo com as respectivas equações:

$$P_j(i, i') = 0, R_{ij} \leq R_{i'j} \quad (2.23)$$

$$P_j(i, i') = 1, R_{ij} > R_{i'j} \quad (2.24)$$

Segue-se a menção à determinação dos índices de preferência para as alternativas, ou o função de preferência agregada com base na seguinte equação:

$$\pi(i, i') = \frac{\sum_{j=1}^m P_{ij}(i, i') w_j}{\sum_{j=1}^m w_j} \quad (2.25)$$

pós a determinação dos índices de preferência, o método PROMETHEE procede ao cálculo dos *outranking flows*, que incluem tanto o fluxo positivo (ou de entrada) quanto o fluxo negativo (ou de saída). Este é calculado através das seguintes expressões:

$$\varphi^+(i) = \frac{1}{n-1} \sum_{i'=1}^n \pi(i', i), (i \neq i') \quad (2.26)$$

$$\varphi^-(i) = \frac{1}{n-1} \sum_{i'=1}^n \pi(i, i'), (i \neq i') \quad (2.27)$$

O fluxo de entrada é uma medida da fraqueza das alternativas, enquanto o fluxo de saída mede a força de cada alternativa.

Em seguida, calcula-se o *net flow*, que é essencialmente a diferença entre o fluxo de entrada e o fluxo de saída para cada alternativa, como pode ser visto na seguinte equação:

$$\varphi(i) = \varphi^+(i) - \varphi^-(i) \quad (2.28)$$

O cálculo do "net flow" desempenha um papel crucial na avaliação e classificação das alternativas, fornecendo uma visão clara de suas posições relativas com base nos pontos fortes e fracos identificados pelos *decision makers*.

Essa métrica permite classificar as alternativas, onde aquelas com um "net flow" maior são consideradas mais favoráveis. Quanto maior o "net flow," melhor a alternativa é avaliada, tornando-o um indicador importante na seleção da opção preferida.

Vantagens

Uma das características distintivas do método PROMETHEE é a sua capacidade de lidar com critérios sem a necessidade de transformações para minimizá-los, o que garante que os dados não sejam distorcidos no processo. Além disso, o PROMETHEE leva em consideração tanto os aspectos positivos quanto os negativos das alternativas, tornando as avaliações mais abrangentes e compreensíveis. Uma vantagem adicional é a facilidade de uso, uma vez que não requer que os critérios sejam proporcionais entre si, como mencionado em [Kraujalienė \[2019\]](#).

Outro ponto a favor do uso do PROMETHEE é sua capacidade de evitar problemas de incomparabilidade entre as alternativas, garantindo que todas as opções possam ser devidamente comparadas e classificadas, conforme destacado em [Rafi et al. \[2020\]](#). Isso contribui para uma tomada de decisão mais informada e objetiva.

Desvantagens

O método PROMETHEE apresenta algumas desvantagens. Primeiramente, não oferece uma estrutura clara para a atribuição de pesos aos critérios, o que torna a determinação das funções de preferência e pesos uma tarefa bastante subjetiva. Isto pode resultar em resultados que refletem fortemente as opiniões dos *decision makers*, como mencionado em [Kraujalienė \[2019\]](#). Além disso, a adição ou remoção de alternativas pode ter um impacto significativo nos resultados finais, o que pode ser um ponto negativo em termos de estabilidade das decisões.

Outra desvantagem a ser considerada é que, assim como no método AHP, as comparações pareadas podem ser pouco eficientes quando o conjunto de alternativas é grande. Portanto, o PROMETHEE pode não ser a melhor escolha para problemas que envolvem um grande conjunto de dados, já que a eficiência pode diminuir consideravelmente à medida que o número de alternativas aumenta, o que pode ser uma

limitação em cenários complexos de tomada de decisão.

2.4 Educational Decision Support Systems

Educational Decision Support Systems (EDSS) são sistemas computadorizados projetados para auxiliar os educadores na tomada de decisões baseadas em dados. Esses sistemas usam EDM e outras técnicas analíticas para analisar grandes quantidades de dados educacionais. O EDSS pode fornecer uma variedade de diferentes tipos de suporte, como referido na revisão da literatura, onde foram explorados problemas como análise preditiva, identificando alunos em risco de ficar para trás ou desistir e fornecer futuramente intervenções direcionadas para apoiá-los [Wati et al. \[2018\]](#).

O EDSS pode ser usado em uma variedade de ambientes educacionais, incluindo escolas primárias e secundárias, faculdades e universidades. Eles podem ajudar os educadores a tomar decisões mais informadas, melhorar os resultados dos alunos e aumentar a eficiência e a eficácia da educação.

Conforme [Klein and Ronen \[2003\]](#) os EDSS têm numeras vantagens, tais como:

- Aprimorar o processo de tomada de decisão: podem fornecer aos educadores percepções baseadas em dados que podem informar as decisões sobre suporte ao aluno e alocação de recursos.
- Aprendizagem personalizada: podem usar dados sobre o desempenho e o comportamento do aluno para criar planos de aprendizagem personalizados e ajustar o nível de dificuldade do conteúdo.
- Análise preditiva: EDSS pode usar análise preditiva para identificar alunos que correm o risco de ficar para trás ou desistir, permitindo que os educadores forneçam intervenções direcionadas.
- Maior eficiência: o EDSS pode automatizar tarefas de rotina, como classificação e avaliação, aos educadores focarem-se em tarefas mais importantes.
- Melhorar os resultados dos alunos: o EDSS pode ajudar os educadores a identificar padrões e tendências nos dados dos alunos e desenvolver estratégias para melhorar os resultados dos alunos.

No entanto, também existem algumas desvantagens potenciais a serem consideradas, [CFI Team](#):

- Privacidade e segurança dos dados: os EDSS dependem de grandes quantidades de dados dos alunos, o que pode gerar preocupações sobre privacidade e segurança dos dados.

- *Bias*: o EDSS pode perpetuar o bias se os dados usados para treinar o sistema forem tendenciosos ou se os algoritmos usados não forem devidamente validados.
- Contexto limitado: EDSS depende de dados, que podem ser limitados em fornecer contexto para certas situações e decisões.
- Dependência de tecnologia: EDSS pode ser limitado pela disponibilidade e qualidade da tecnologia e pelas habilidades dos formadores que a utilizam.
- Custo: Desenvolver e manter o EDSS pode ser caro e pode haver falta de financiamento para certas escolas ou instituições para implementá-lo.

Existem várias ferramentas e tecnologias que podem ser usadas para desenvolver sistemas de apoio à decisão, incluindo ferramentas de visualização de dados, como Tableau e Power BI que permitem a criação de painéis interativos que podem ajudar os utilizadores a entender e analisar melhor os dados.

Estruturas de machine learning e inteligência artificial, como é o caso do TensorFlow e scikit-learn que fornecem uma ampla variedade de algoritmos e bibliotecas que podem ser usados para criar modelos preditivos e outros recursos avançados de análise. Linguagens de programação como Python, Java, C++ também são amplamente utilizadas para o desenvolvimento de DSS [Thangamuthu and Nallasamy \[2017\]](#).

Parte II

Core da Dissertação

Capítulo 3

Métodos e Metodologias

3.1 Proposta de Arquitetura

A proposta de arquitetura para esta dissertação aborda um problema crítico no sistema educacional: a identificação de alunos em risco de insucesso e, conseqüentemente, de abandono escolar. O processo envolve várias etapas, desde a recolha inicial de dados dos alunos até a geração de uma lista ordenada dos alunos em risco. Neste contexto, a arquitetura proposta visa integrar eficazmente essas etapas, otimizando a análise preditiva e a tomada de decisão por meio de métodos multi-critério.

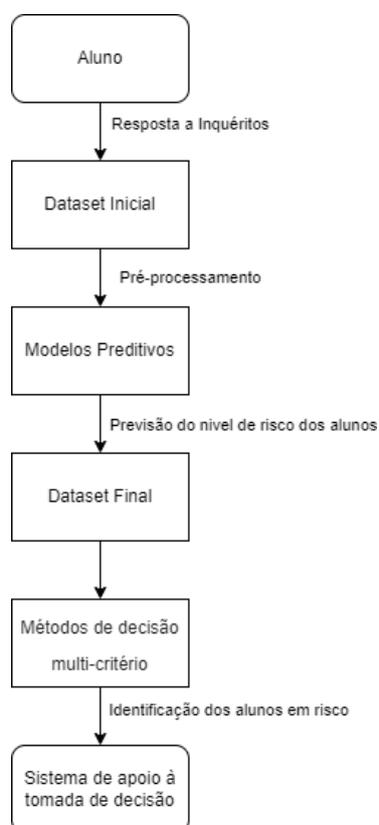


Figura 7: Proposta de arquitetura geral

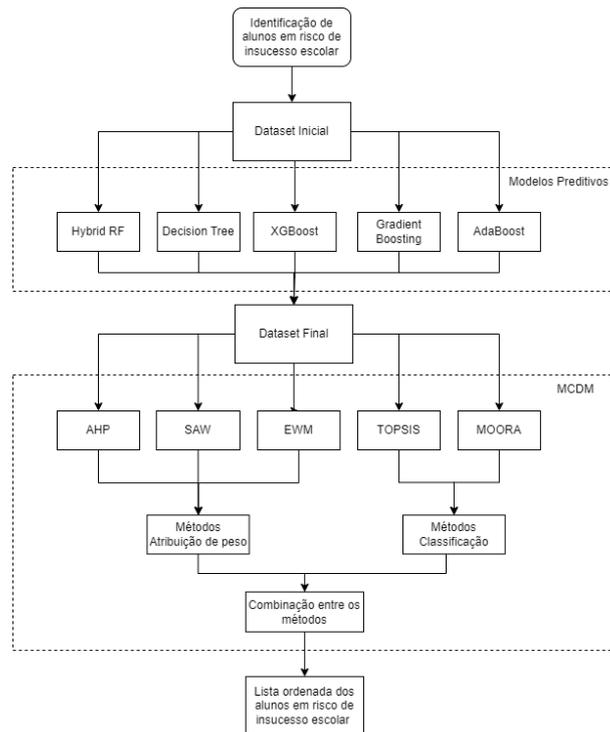


Figura 8: Proposta de arquitetura detalhada

O primeiro passo da proposta é a aquisição de um conjunto de dados iniciais, que contém informações relevantes sobre os alunos no ensino secundário, como histórico acadêmico, dados sociobiográficos, informações socioeconômicas, entre outros. É importante ressaltar que esses dados foram obtidos por meio da cooperação dos alunos que responderam a questionários elaborados por psicólogos e entidades relacionadas. Este conjunto de dados é então submetido a um rigoroso processo de pré-processamento, incluindo limpeza, normalização e transformação, para garantir a qualidade e a consistência dos dados.

Após o pré-processamento, o conjunto de dados é introduzido em modelos de análise preditiva. Esses modelos são treinados para prever e classificar o nível de risco de insucesso escolar de cada aluno. Diversos algoritmos de *machine learning* são testados e avaliados, sendo estes: Hybrid Random Forest, Decision Tree, XGBoost, Gradient Boosting e AdaBoost.

Os resultados das previsões do modelo são incorporados no dataset final. Essa inclusão dos resultados preditivos no conjunto de dados permite que as informações sobre o risco de insucesso de cada aluno estejam prontamente disponíveis para as etapas subsequentes do processo.

Segue-se a aplicação de métodos multi-critério para apoio à tomada de decisão. Neste caso de estudo, os métodos estudados foram: AHP, SAW, EWM, TOPSIS e MOORA. Estes métodos consideram várias dimensões de avaliação, como desempenho acadêmico, envolvimento escolar, entre outros, para atribuir pesos e classificar os alunos em termos de risco de insucesso escolar. O resultado desses métodos é

uma lista ordenada dos alunos, identificando aqueles com maior probabilidade de enfrentar dificuldades acadêmicas.

A lista ordenada de alunos em risco de insucesso escolar gerada pelos métodos multi-critério é a solução ao problema principal desta pesquisa, servindo como sistema de apoio à tomada de decisão, uma vez que, permite que os profissionais da educação identifiquem de forma eficaz e eficiente os alunos que enfrentam maior probabilidade de insucesso no ensino secundário. Essa lista oferece uma base sólida para que instituições educacionais possam tomar medidas pro-ativas e direcionadas para apoiar os alunos em risco, reduzindo assim a taxa de abandono escolar.

A arquitetura proposta combina eficazmente modelos de análise preditiva com métodos multi-critério para criar uma solução abrangente e orientada para a ação na identificação de alunos em risco de insucesso escolar e consequente abandono. Ela representa um passo importante na melhoria do sistema educacional, permitindo que os recursos sejam direcionados de forma eficiente para atender às necessidades dos alunos com uma maior carência acadêmica.

3.2 Dataset

Os dados utilizados neste projeto, conforme referido anteriormente, foram recolhidos por meio de inquéritos realizados em escolas com alunos do 2º e 3º ciclo. Esses alunos abrangem cinco anos letivos, sendo cada turma composta por aproximadamente 20 alunos. Para detalhar, o 5º e o 6º ano possuem cinco turmas cada, totalizando aproximadamente 200 alunos, distribuídos igualmente. Já nos 7º, 8º e 9º anos, o coletivo é de 266 alunos, divididos em turmas de cerca de 20 alunos cada. Os inquéritos abrangeram uma variedade de questões, desde questões de natureza geral a outras específicas para cada aluno.

As respostas dos alunos consistiram principalmente em dados diretos, como notas, e em respostas que se encaixavam em uma escala. Por exemplo, algumas questões foram avaliadas em uma escala que variava desde 'discordo totalmente' a 'discordo', 'não tenho a certeza', 'concordo' e 'concordo totalmente'. Essa escala foi posteriormente traduzida para valores numéricos, variando de 1 a 5, respetivamente.

Aqui estão alguns exemplos dos dados encontrados nos inquéritos realizados:

Tabela 3: Dados do Dataset Original

Pessoais	Sociobiograficos	Escolares	Inquéritos
Nome	Escalão	Nome do curso	"Se para o aluno é importante mostrar que é mais inteligente"
Género	Situação de habitação	Nome da disciplina	"Se é importante evitar mostrar que tem dificuldades a fazer os trabalhos"
Idade	Ano de escolaridade do pai	Nota na disciplina	"Se entrega os trabalho de casa a tempo"
Naturalidade	Ano de escolaridade da mãe	Média interna	"Se participa ativamente nas aulas"
Localidade	Meio de transporte	Autoavaliação	"Se frequenta explicações. Se sim, quantos dias por semana frequenta e que tipo de explicações"
Ano de escolaridade	Estado civil dos pais	Situação escolar	"Que satisfação tem com as suas notas"

O conjunto de dados original é composto por 123 atributos que abrangem as respostas dos alunos ao questionário. Esses atributos variam desde informações mais gerais, como género, idade e notas, até aspetos mais pessoais, como satisfação com as notas e nível de envolvimento escolar.

3.3 Requisitos Funcionais e não funcionais

Requisitos Funcionais

- O sistema deve ter a capacidade de realizar previsões sobre o nível de risco de insucesso escolar de um aluno com base nos dados disponíveis sobre esse aluno;
- O sistema deve ser capaz de representar de forma precisa e fiel o contexto educacional em que está inserido;
- O sistema deve ser capaz de classificar e identificar de maneira eficiente os alunos que apresentam um maior risco de enfrentar dificuldades académicas ou de abandonar a escola;

- O sistema deve ser transparente em relação aos resultados produzidos, tornando compreensíveis as bases e critérios utilizados para identificar e classificar os alunos em risco

Requisitos Não Funcionais

- O sistema deve oferecer aos utilizadores finais uma interface simples e de fácil compreensão, que permita uma visualização direta e clara dos resultados obtidos;
- O sistema deve manter a transparência em relação aos resultados gerados, assegurando que os critérios e processos que levaram às classificações dos alunos em risco sejam facilmente compreensíveis para os utilizadores;
- O sistema deve garantir a segurança dos dados dos alunos;
- O sistema deve ser altamente confiável, assegurando que as respostas e classificações fornecidas sejam consistentes e corretas

Capítulo 4

Aplicações

Neste capítulo, é detalhada a aplicação prática dos modelos preditivos estudados para a sua utilização nos Sistemas de Apoio à Decisão (SADs), bem como os métodos de multi-critério utilizados. Aqui, aplicamos os modelos preditivos e métodos multi-critério discutidos anteriormente integrando-os nos sistemas de apoio à decisão que desempenharão um papel fundamental no processo de decision making.

Esta fase de implementação não demonstra apenas a aplicabilidade da arquitetura proposta, mas também oferece *insights* sobre os desafios encontrados e as soluções desenvolvidas para otimizar a utilidade e a eficácia desses sistemas.

4.1 Tratamento de dados

Dada a diversidade em termos de natureza e tipos dos dados recolhidos, foi essencial realizar um processo de tratamento apropriado. Esse processo teve como objetivo garantir a qualidade dos dados como também torná-los aptos a serem utilizados por modelos de machine learning, e seguiu a estrutura CRISP-DM.

Em primeiro lugar, uma vez que estes dados provém de um questionário aplicado a alunos com menos de 16 anos, foi necessário assegurar que apenas os dados autorizados pelos encarregados de educação seriam usados. Após essa seleção, ficamos com dados de 845 alunos.

A remoção de valores nulos e duplicados foi outro passo essencial. Após uma primeira análise foi possível verificar que cerca de 28 colunas apresentavam valores nulos, conforme podemos observar em

[4](#).

Tabela 4: Variáveis com valores nulos

Nota Português	1
Nota Matematica	1
Q_Internalizacao_Externatizacao	422
Bully	422
Vitima	422
Q18 Internalizacao_Externatizacao_12	422
Q18 Internalizacao_Externatizacao_11	422
Q18 Internalizacao_Externatizacao_10	422
Q18 Internalizacao_Externatizacao_9	422
Q18 Internalizacao_Externatizacao_8	422
Q18 Internalizacao_Externatizacao_7	422
Q18 Internalizacao_Externatizacao_6	422
Q18 Internalizacao_Externatizacao_5	422
Q18 Internalizacao_Externatizacao_4	422
Externalizacao	422
Internalizacao	422
Q18 Internalizacao_Externatizacao_1	422
Q17_relacao_pares_8	422
Q17_relacao_pares_7	422
Q17_relacao_pares_6	422
Q17_relacao_pares_5	422
Q17_relacao_pares_4	422
Q17_relacao_pares_3	422
Q17_relacao_pares_2	422
Q17_relacao_pares_1	422
Q18 Internalizacao_Externatizacao_3	422
Q9_Tipo_de_explicação	567
Q10_Quantos_dias_semana	568

A maior quantidade de valores nulos recai na questão 10 do formulário que referencia o numero de dias por semana que os alunos tem tutoria e que tipo de tutoria tem. A razão pela qual há tantos valores nulos é porque a maioria dos alunos não tem tutoria e, portanto, deixou a questão em branco. A solução então foi preencher esses valores nulos com 0. Houve também um aluno que não respondeu qual era a nota em Português e Matemática do 1º período. Para não descartar as informações restantes fornecidas, esses valores ausentes foram substituídos pela nota média em ambas as disciplinas. Ainda assim todas estas colunas apresentam um elevado numero de valores nulos e não forneciam informações significativas, por isso foram descartadas. Colunas como “nome do aluno” e “turma”, usadas principalmente para identificação de alunos, foram eliminadas. A eliminação dessas colunas não removeu apenas informações irrelevantes para o modelo, mas também garantiu a segurança e preservação do anonimato dos alunos.

Foi ainda feita uma seleção de atributos, sendo que o dataset continha vários dados irrelevantes para o caso de estudo, conforme referido acima.

No artigo [Lacerda et al. \[2023\]](#), que utiliza este conjunto de dados para realizar uma análise por meio de *data mining*, são identificados os principais fatores que influenciam a reprovação do alunos. Com base nesse estudo, juntamente com os objetivos deste projeto, foi decidido que, do conjunto de dados original, apenas 6 atributos seriam selecionados para prever o nível de risco de um aluno. O resumo do conjunto de dados resultante é apresentado na Tabela [5](#).

Tabela 5: *Dataset Final*

Atributo	Resumo	Tipo
Q20_nota_português_2.ºperíodo	Nota de português referente ao 2º período escolar	Float, varia de 1.0 a 5.0
Q26_nota_mat_2.ºperíodo	Nota de matemática referente ao 2º período escolar	Float, varia de 1.0 a 5.0
Q16_satisfação_com_notas_escolares	Grau de satisfação do aluno com as suas notas	Float, varia de 1.0 a 5.0
Q15_as_minhas_notas	Notas que não correspondem ao que os alunos consideram que conseguem fazer	Float, varia de 1.0 a 5.0
Envolvimento <i>Scoretotal</i>	Medida de empenho e envolvimento na escola e atividades extra-curriculares	Float, varia de 0 a 25
Cluster	Nível de risco do aluno	Float, varia de 1 a 4

Os primeiros dois atributos do conjunto de dados correspondem às notas obtidas pelos alunos nas disciplinas de Português e Matemática durante o segundo período escolar. Estas notas são avaliadas numa escala de 1 a 5, onde 1 representa um desempenho negativo e 5 indica um desempenho excelente.

Em seguida, temos a avaliação do nível de satisfação dos alunos com as suas notas nas disciplinas, que é classificada numa escala de 1 a 5. Nessa escala, o valor 1 indica que o aluno está insatisfeito com as suas notas, enquanto que o valor 5 representa que o aluno está bastante satisfeito com suas notas.

A questão 15, sobre as notas dos alunos, avalia o quanto as notas representam o desempenho geral do aluno. De maneira mais simples, é calculada como uma média das notas do aluno e é pontuada numa escala de 1 a 5.

Por fim temos o *cluster*, o *cluster* representa o grupo de risco em que um aluno é identificado, sendo estes os seguintes:

Cluster 1: Nível de risco alto, notas abaixo da média, satisfação com as notas abaixo da média, notas que não correspondem ao que os alunos consideram que conseguem fazer e envolvimento na escola abaixo da média.

Cluster 2: Nível de risco médio, notas abaixo da média, satisfação com as notas média, notas que correspondem ao que os alunos consideram que conseguem fazer e médio envolvimento escolar.

Cluster 3: Nível de risco médio, notas médias, satisfação com as notas média, notas que não correspondem ao que os alunos consideram que conseguem fazer e médio envolvimento escolar.

Cluster 4: Nível de risco baixo, notas acima da média, satisfação com as notas acima da média, notas que correspondem ao que os alunos consideram que conseguem fazer ou um pouco acima e envolvimento escolar acima da média.

Tabela 6: Perfis de risco

<i>Cluster</i>	Perfil
Nível risco alto - 1	Média nota português - 2.86 Média nota matemática - 2.77 Média Satisfação - 2.73 Média Autoavaliação - 2.18 Média Envolvimento - 16.63
Nível risco médio - 2	Média nota português - 3.15 Média nota matemática - 3.34 Média Satisfação - 3.94 Média Autoavaliação - 3.30 Média Envolvimento - 19.93
Nível risco médio - 3	Média nota português - 4.03 Média nota matemática - 3.93 Média Satisfação - 3.69 Média Autoavaliação - 2.56 Média Envolvimento - 19.88
Nível risco baixo - 4	Média nota português - 4.54 Média nota matemática - 4.75 Média Satisfação - 4.79 Média Autoavaliação - 3.54 Média Envolvimento - 21.76

4.2 Modelos Preditivos

Após a etapa de pré-processamento dos dados, passamos à aplicação dos modelos de machine learning para prever os alunos em situação de risco. É importante destacar que a variável alvo para essa previsão é o *cluster*. Para cada aluno, com base nas características previamente escolhidas, será atribuído um valor de 0 a 3. Nesse contexto, os valores 0 e 1 indicam alunos em alto risco de insucesso, enquanto os valores 2 e 3 indicam alunos em baixo risco.

Levando em consideração o tipo de dado a ser trabalhado e o objetivo deste trabalho, foram utilizados modelos de aprendizado supervisionado. Os modelos selecionados foram Hybrid Random Forest [Phauk](#)

and Okazaki [2020a], Decision Tree Kabra [2011], XGBoost e Boosting Giannakas et al. [2021], por serem os mais utilizados neste domínio segundo a literatura.

Para o modelo Hybrid Random Forest foi utilizado o algoritmo Random Forest Classifier bem como o Principal Component Analysis também conhecido como PCA, e *cross validation* Phauk and Okazaki [2020a]. Quanto aos algoritmos de Boosting foi utilizado Gradient Boosting e AdaBoost Giannakas et al. [2021].

Em todos os modelos foi utilizado Grid Search para encontrar os melhores parâmetros para cada modelo. A *cross validation*, com 10 *folds*, também foi executada em todos os modelos para avaliar o modelo e garantir que não houve *overfitting*.

4.2.1 Avaliação

Para garantir que nossos modelos preditivos são eficazes, avaliamos o desempenho através de *F1-score*, *Precision* e *Recall*. Estes oferecem uma avaliação mais precisa do desempenho do modelo garantindo uma avaliação justa.

4.2.2 Resultados e Discussão

O primeiro modelo desenvolvido foi a Hybrid Random Forest. Para este modelo o primeiro passo foi padronizar os dados, após isso foi aplicado o algoritmo PCA. A Análise de Componentes Principais (PCA) é uma técnica estatística que é amplamente utilizada para reduzir a dimensionalidade de um conjunto de dados, enquanto tenta manter as informações mais significativas contidas nele. Para escolher o número de componentes foram realizado testes de forma a encontrar o numero ideal. Este numero varia entre 0 e o numero de atributos, uma vez que o numero de atributos, sem contar com a classe *target*, é 5 e uma vez que 0 não é viável para posteriormente ser aplicado no modelo então o teste foi realizado de 1 a 5, conforme a tabela abaixo:

Tabela 7: Caption

Métrica	Explicação
Accuracy	É uma métrica de avaliação que permite analisar a porcentagem de amostras que o sistema foi capaz de calcular corretamente.
Precision	É a razão dos casos positivos que foram identificados corretamente pelo modelo tendo em conta todos os casos positivos previstos.
Recall	É a razão entre os casos positivos identificados corretamente pelo modelo tendo em conta os casos positivos reais.
F1-score	Esta métrica combina as métricas precision e recall com o objetivo de identificar a qualidade geral do modelo gerado, pode também ser interpretada como uma média ponderada entre elas. Permite medir o quão precisos os resultados do modelo são para os dados de teste.

Tabela 8: Teste componentes PCA

Numero de Componentes	Accuracy s/ cross validation	Accuracy c/ cross validation
1	0.686391	0.854829
2	0.840237	0.911128
3	0.946746	0.945193
4	0.958580	0.943613
5	0.964497	0.968810

Como evidenciamos, o número ideal de componentes é 5 para obter os melhores resultados. Com isso em mente, aplicamos o algoritmo Random Forest Classifier e otimizando os seus parâmetros usando a técnica de Grid Search. Os parâmetros otimizados incluíram a profundidade máxima (*max depth*), o número mínimo de amostras necessárias para dividir um nó (*min samples split*) e o número mínimo de amostras necessárias para ser uma folha (*min samples leaf*). O valor ideal encontrado para a profundidade máxima (*max depth*) foi 10. O segundo modelo desenvolvido foi a Decision Tree. Para este modelo, aplicamos diretamente o algoritmo Decision Tree Classifier, otimizando os parâmetros, que incluíam a profundidade máxima (*max depth*), o número mínimo de amostras necessárias para dividir um nó (*min samples split*), o número mínimo de amostras necessárias para ser uma folha (*min samples leaf*) e o critério de divisão. Os valores ideais encontrados para esses parâmetros foram: profundidade máxima (*max depth*) igual a 12, número mínimo de amostras para dividir um nó (*min sample split*) igual a 1 e critério (*criterion*) igual a entropia (*entropy*).

O terceiro modelo desenvolvido foi o XGBoost. Neste modelo, aplicamos diretamente o algoritmo XGBoost Classifier, otimizando os parâmetros que incluíam a profundidade máxima (*max depth*), o peso mínimo das amostras filhas (*min child weight*), o valor gama (*gamma*), a taxa de amostragem (*subsample*) e a taxa de colunas por árvore (*colsample bytree*). Os valores ideais encontrados para esses parâmetros foram: profundidade máxima (*max depth*) igual a 1 e gamma igual a 0.5.

Por fim, o quarto modelo a ser desenvolvido foi o Gradient Boosting Classifier e o quinto modelo a ser desenvolvido foi o ADA Boost Classifier.

A seguir, são apresentados os resultados obtidos para a previsão dos *clusters* pelos diferentes modelos.

Tabela 9: Classification report - Cluster 0

Model	Precision	Recall	F1-score	Support
Hybrid Random Forest	0.98	0.98	0.98	44
Decision Tree	0.91	0.89	0.90	44
XGBoost	0.98	1.00	0.99	44
Gradient Boosting	0.95	0.93	0.94	44
AdaBoosting	0.94	0.77	0.85	44
accuracy			0.93	44

Tabela 10: Classification report - Cluster 1

Model	Precision	Recall	F1-score	Support
Hybrid Random Forest	0.95	0.95	0.95	40
Decision Tree	0.86	0.95	0.90	40
XGBoost	1.00	0.97	0.99	40
Gradient Boosting	0.93	0.97	0.95	40
AdaBoosting	0.78	0.95	0.85	40
accuracy			0.96	169

Quando se trata de prever os alunos com maior risco de insucesso escolar, alunos que pertencem tanto ao cluster 0 como ao 1, podemos observar pelas Tabelas 9 e 10 que o XGBoost obteve globalmente melhor métricas. Também observando todos os seus resultados na predição de diferentes clusters, podemos verificar que este modelo alcançou uma *accuracy* geral de 99% antes da *cross validation*. E aproximadamente 96,4% após *cross validation*.

Tabela 11: Classification report - Cluster 2

Cluster	Precision	Recall	F1-score	Support
Hybrid Random Forest	0.93	0.95	0.94	40
Decision Tree	1.00	0.88	0.93	40
XGBoost	0.98	1.00	0.99	40
Gradient Boosting	0.97	0.88	0.92	45
AdaBoosting	0.91	0.97	0.94	40
accuracy			0.92	169

Tabela 12: Classification report - Cluster 3

Cluster	Precision	Recall	F1-score	Support
Hybrid Random Forest	1.00	0.98	0.99	45
Decision Tree	0.94	0.98	0.96	45
XGBoost	1.00	0.98	0.99	45
Gradient Boosting	0.94	1.00	0.97	45
AdaBoosting	0.98	0.89	0.93	45
accuracy			0.99	169

Quanto à previsão de alunos em menor risco de insucesso escolar, pertencentes ao cluster 2 ou 3, podemos observar que o XGBoost ainda mantém métricas globais melhores do que os outros métodos. Para o cluster 3, o modelo Hybrid Random Forest obteve métricas iguais ao XGBoost, mas quando comparado aos outros clusters, verificamos que esse modelo alcançou apenas uma *accuracy* geral de 96% antes da *cross validation*. E aproximadamente 97% após *cross validation*.

Em relação aos restantes modelos, como Decision Tree, Gradient Boosting e AdaBoost, obtiveram uma *accuracy* geral de 94,5%, 95,8% e 70% após a *cross validation*, respectivamente.

Com foco nas questão de investigação, o XGBoost demonstrou a maior *accuracy* e métricas gerais, atingindo 99%, tornando-o o modelo ideal para usar para esse tipo de conjunto de dados.

Assim, ao utilizar os seis recursos do conjunto de dados, que incluem resultados de português e matemática no segundo período escolar, satisfação do aluno com o seu desempenho, avaliações do aluno e pontuação total de envolvimento na escola, podemos determinar com precisão o nível de risco de insucesso escolar para cada aluno.

4.3 Multi-Criteria Decision Making Methods

Após a previsão do nível de risco dos alunos, essa informação foi incorporada ao conjunto de dados como uma nova coluna. Em seguida, aplicamos diversos métodos de tomada de decisão multi-critério, conforme discutido no Capítulo 2, com o objetivo de aprimorar o processo de tomada de decisão. Esses dados, apoiados pelos métodos de tomada de decisão multi-critério, têm o potencial de fornecer aos educadores percepções baseadas em dados que podem ser usadas para tomar decisões informadas sobre o suporte e intervenção de alunos em situação de risco. Diante desses dados e com o propósito de

auxiliar professores e autoridades responsáveis quando a necessidade de apoio e intervenção de um aluno em risco se apresenta, foram testados vários métodos que, com base em múltiplos critérios, ajudam a determinar quais alunos necessitam de apoio mais significativo e/ou intervenção mais imediata.

Em essência, a finalidade dos MCDM é auxiliar os tomadores de decisão na escolha preferencial entre as opções disponíveis, que são caracterizadas por diversos atributos, frequentemente em conflito.

Com base no tipo de dados a serem processados e nos objetivos deste trabalho, foram selecionados os métodos SAW, AHP, EWM, TOPSIS e MOORA. Estes métodos foram escolhidos devido à sua ampla utilização neste domínio, conforme relatado na literatura.

Além disso, todos os métodos selecionados foram aplicados de acordo com os procedimentos descritos na secção 2.3.

Conforme mencionado anteriormente, existem métodos mais específicos para a atribuição de pesos e outros voltados para a classificação das alternativas.

Para todos os métodos em que a atribuição de pesos e impactos prévios foi necessária, esses valores foram definidos de acordo com a Tabela 13. Os impactos representam o tipo de influência que os atributos têm no problema em questão. No contexto deste estudo, todos os atributos estão relacionados a custos ou têm um efeito negativo no problema, ou seja, quanto menores as notas, a satisfação, o envolvimento e o nível de risco, pior é a situação do aluno.

Tabela 13: Atribuição de Pesos

Atributos	Pesos	Impacto
Nota Português	0.25	neg
Nota Matemática	0.25	neg
Satisfação com notas	0.075	neg
As minhas notas	0.15	neg
Envolvimento	0.075	neg
Cluster	0.2	neg
Total	1.00	

Nesta tabela, são exemplificados os pesos atribuídos aos atributos, identificando aqueles que são igualmente importantes e os mais essenciais dentro do conjunto de dados para a identificação de alunos em risco. Em primeiro lugar, as notas dos alunos são consideradas os atributos mais cruciais, uma vez que servem como principais indicadores. O segundo atributo de maior importância é o *cluster*. No entanto, dada a natureza preditiva desse e o seu vínculo com as notas dos alunos, a sua importância é

ligeiramente inferior em comparação com as próprias notas.

De seguida, temos as notas que refletem as capacidades dos alunos. Por fim, a satisfação dos alunos com as suas notas e o envolvimento escolar que também são atribuídos com igual importância na avaliação dos alunos em risco.

Entre os métodos implementados, AHP e EWM, nestes não são atribuídos pesos prévios aos atributos. O método AHP utiliza uma matriz de comparações em pares para determinar o vetor de pesos dos atributos, enquanto que o método EWM utiliza a entropia para determinar esse mesmo vetor de pesos.

Esses métodos são principalmente usados para a atribuição de pesos aos atributos, sendo eficazes na tarefa de determinar a importância relativa de cada atributo no contexto da tomada de decisão.

O método SAW, embora atribua pesos aos critérios antecipadamente, não pode ser considerado um método de classificação. Isto ocorre porque o SAW não envolve a categorização de dados em classes ou categorias predefinidas, que é a função principal dos classificadores. Em vez disso, o SAW concentra-se na comparação e classificação de alternativas com base nas suas pontuações agregadas.

Por outro lado, os métodos TOPSIS e MOORA são amplamente utilizados para a classificação de alternativas. No entanto, caso não sejam utilizados em conjunto com um método de atribuição de pesos, é necessário atribuir pesos à priori aos atributos para a realização da classificação das alternativas.

Desta forma, os métodos são geralmente integrados para se complementarem. Os métodos de atribuição de pesos permitem que os métodos de classificação tenham acesso aos vetores de pesos, eliminando subjetividades, tornando os métodos mais robustos e compreensíveis.

Com base nos estudos realizados na revisão da literatura, foram desenvolvidos conjuntos de métodos que incluem: AHP-TOPSIS, AHP-MOORA, SAW-TOPSIS, SAW-MOORA, EWM-TOPSIS e EWM-MOORA. Esses conjuntos foram implementados para tirar proveito das vantagens de ambos os tipos de métodos, combinando a atribuição de pesos objetiva com a classificação eficaz de alternativas.

O método AHP-TOPSIS, aproveita as funcionalidades do método AHP, que utiliza a matriz de comparações em pares conforme apresentada na Tabela 14 para determinar o vetor de pesos dos critérios. Esse vetor de pesos, por sua vez, é utilizado pelo método TOPSIS para classificar as alternativas. Este método tem sido amplamente estudado e aplicado na área em questão [Rianto et al. \[2017\]](#).

De maneira semelhante, o método AHP-MOORA funciona nas mesmas bases. O método AHP fornece o vetor de pesos, e o método MOORA é utilizado para a classificação das alternativas.

Os métodos SAW-TOPSIS, SAW-MOORA, EWM-TOPSIS e EWM-MOORA funcionam nas mesmas premissas de atribuição de pesos (usando SAW e EWM) e classificação de alternativas (usando TOPSIS e MOORA) para melhorar o processo de tomada de decisão.

4.3.1 Resultados

Análise do método AHP

Para AHP, foi necessário construir uma matriz de comparações pareadas com base na importância relativa dos atributos. Tendo por base a escala Saaty, a tabela resultante foi a seguinte:

Tabela 14: Matriz de comparações pareadas - AHP

	Nota Português	Nota Matemática	Satisfação	Minhas Notas	Envolvimento	Cluster
Nota Português	1	1	7	5	7	3
Nota Matemática	1	1	7	5	7	3
Satisfação	1/7	1/7	1	1/4	1	1/6
Minhas Notas	1/5	1/5	4	1	4	1/3
Envolvimento	1/7	1/7	1	1/4	1	1/6
Cluster	1/3	1/3	6	3	6	1

A leitura correta desta tabela explica as relações de importância entre atributos. Por linhas conseguimos concluir que, a nota de português e matemática tem o mesmo valor de importância, a nota de português é 7 vezes mais importante, ou muito fortemente favorecido, que o atributo de satisfação e envolvimento. É ainda 5 vezes mais importante, ou fortemente favorecido, do que o atributo minhas notas, e por fim 3 vezes mais importante, ou moderadamente favorecido do que, o *cluster* de previsão de nível de risco.

Para a nota de matemática, as comparações em relação aos restantes atributos é igual as nota de português, uma vez que estes apresentam igual importância no dataset.

Na terceira linha que explica a relação do atributo satisfação em relação aos restantes, diz-nos que, uma vez que a nota de português e matemática são 7 vezes mais importantes do que a mesma, então por consequência a sua importância é 1/7 em relação as mesmas. Temos ainda que a satisfação e o envolvimento tem a mesma importância. Por fim, as minhas notas demonstram uma importância 4 vezes superior, ou moderada, sobre a satisfação. O *cluster* revela uma importância fortemente favorecida.

Na quarta linha temos ainda a informação que as minhas notas é 4 vezes mais importante que o envolvimento, bem como na satisfação como foi visto acima. Vimos ainda que o *cluster* é 3 vezes mais importante do que as minhas notas.

Na quinta linha observamos mais uma vez que o envolvimento e a satisfação partilham o mesmo grau de importância e que o *cluster* é 6 vezes mais importante que este.

Por fim, na última linha conseguimos verificar no cluster as suas importâncias relativas conforme aquilo que já foi definido anteriormente.

Após a construção da matriz de comparações pareadas, o método AHP foi aplicado. O vetor de pesos resultante é apresentado na tabela a seguir:

Tabela 15: Vetor de pesos - AHP

	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Vetor pesos	0.33067549	0.33067549	0.03620916	0.09367133	0.03620916	0.17255938

Com base no vetor calculado, a análise de consistência foi realizada. Uma vez que o Índice de Consistência (CR) é menor que 0.1000, podemos concluir que os pesos relativos atribuídos são consistentes e podem ser utilizados com confiança.

Tabela 16: Caption

CR	0.04497134217755041
----	---------------------

Uma vez que esses métodos de atribuição de pesos não têm a capacidade de classificar as alternativas por si só, eles são integrados ao método SAW. Esta integração permite que os pesos atribuídos aos atributos sejam somados, fornecendo às alternativas um peso global. Esse peso global pode então ser usado para "classificar" as alternativas, sendo ordenadas de acordo com esse critério.

O resultado obtido pode ser visualizado na tabela seguintes:

Tabela 17: Resultados alunos Alto Risco - AHP

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 248	2	2	2	1	16	0
Id 259	2	2	1	1	18	0
Id 113	2	2	2	1	17	0
Id 814	2	2	3	2	14	0

Tabela 18: Resultados alunos Baixo Risco - AHP

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 64	5	5	5	5	25	3
Id 199	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 743	5	5	5	5	25	3
Id 651	5	5	5	5	25	3

A primeira análise a ser realizada envolve o vetor de pesos, com base na comparação dos pesos atribuídos aos critérios na Tabela 12.

Podemos observar que, apesar dos valores diferentes atribuídos, eles mantêm uma relação idêntica. Tanto Português quanto Matemática têm o mesmo peso ou importância, assim como acontece com Satisfação e Envolvimento. Além disso, as notas em Português e Matemática apresentam uma maior importância em relação aos demais, seguidas pelo Cluster, Minhas Notas e, por fim, Satisfação e Envolvimento. Essas relações são consistentes e refletem o processo de atribuição manual de pesos aos critérios pelos *stakeholders*. Isto faz sentido, uma vez que a tabela de comparações em pares foi construída com base nas relações entre os atributos.

Em relação às alternativas, podemos observar que os alunos com maior risco de insucesso escolar têm notas baixas, 2 (consideradas negativas), tanto em Português quanto em Matemática. Além disso, eles são atribuídos ao Cluster 0, que representa o nível 1, considerado de alto risco.

No critério as suas notas, estes tem o valor 1 ou 2 (negativo), sendo que este reflete as capacidades dos alunos.

Por fim temos que a satisfação com as notas varia entre 1 e 2, ambos valores negativos, ou seja, estes alunos não se encontram satisfeitos com as suas notas. Quanto ao envolvimento este varia entre 12 e 18. Demonstrando a sua baixa participação e falta de envolvimento em atividades escolares.

No caso dos alunos de baixo risco, podemos observar que eles obtêm notas excelentes, com valores de 5, tanto a Matemática quanto a Português. Essas notas refletem as suas capacidades e, além disso, estão satisfeitos com suas notas. Também é notável que esses alunos demonstram um alto envolvimento nas atividades escolares. Por fim, todos esses alunos pertencem aos grupos calculados como de baixo risco.

Este dados vão de acordo com o estudo feito para atribuição dos perfis de risco ou clusters dos alunos. Como visto em 6, no perfil de risco 1, as notas destes alunos rondam os 2 valores tal como as

suas capacidades e satisfação com as notas. O envolvimento ronda por volta dos 16 valores. No perfil de risco 4, as notas destes alunos rondam os 5 valores tal como as suas capacidades e satisfação com as notas. O envolvimento ronda por volta dos 25 valores. Os nossos resultados apresentam valores de média bastante semelhantes.

Análise do método EWM

Neste método, o vetor de pesos é calculado exclusivamente através do cálculo da entropia dos atributos correspondentes, tornando-o um dos métodos com menor subjetividade. A aplicação deste método segue os procedimentos mencionados na secção 2.3 deste documento.

O vetor de pesos obtido foi o seguinte:

Tabela 19: Vetor de pesos - EWM

	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Vetor pesos	0.17202511	0.17133342	0.17064950	0.17024726	0.17280566	0.14293905

Observando este vetor de pesos e fazendo referência à Tabela 12, podemos concluir que todos os critérios têm valores semelhantes, com a principal discrepância ocorrendo no atributo Cluster, que possui uma importância inferior em comparação aos restantes. Neste caso, o Envolvimento e a Nota de Português apresentam uma importância maior em relação aos demais atributos, seguidos pela Nota de Matemática, a Satisfação e, por fim, as minhas Notas.

Essa classificação não coincide completamente com o que os *stakeholders* atribuíram como representativo da relação entre os atributos, no entanto, está próximo do previsto.

Isto ocorre porque o método de entropia baseia-se na ideia de equilíbrio, em que os pesos são calculados para maximizar a informação fornecida pelos atributos e minimizar a incerteza. Por outro lado, os pesos atribuídos pelos *stakeholders* tendem a ser subjetivos, refletindo preferências e experiências individuais.

Em relação às alternativas, como já foi referido, tanto o método AHP quanto o EWM são incorporados ao método SAW para que seja possível apresentar os seus resultados.

Tabela 20: Resultados alunos Alto Risco - EWM

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 453	3	2	3	2	6	0
Id 721	4	2	1	1	8	0
Id 418	4	3	1	1	8	0
Id 496	2	2	2	1	12	0
Id 412	3	4	2	2	9	0

Tabela 21: Resultados alunos Baixo Risco - EWM

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 64	5	5	5	5	25	3
Id 651	5	5	5	5	25	3
Id 199	5	5	5	5	25	3
Id 743	5	5	5	5	25	3
Id 61	5	5	5	5	25	3

Conforme a tabela 20, podemos verificar que aparte do critério cluster onde todos se classificam no cluster 0, os valores dos restantes critérios variam bastantes.

Podemos observar que para o critério com maior peso, envolvimento escolar, os valores variam de 6 a 9, sendo portanto os alunos que menos se envolvem nas atividades escolares os que tem maior peso na sua classificação. Ou seja, é este o critério que identifica os alunos em maior risco de insucesso escolar.

No entanto podemos observar que as notas de Português são de uma forma geral satisfatórias, com uma média de 3, e para Matemática uma média de 2 valores.

Este método é o que faz menos sentido a nível de classificação das alternativas, é difícil compreender como pode um aluno com uma notas média de 3 valores ser um aluno de risco maior do que um aluno com notas de 2 valores apenas com base no seu envolvimento na escola.

Em relação aos alunos de baixo risco, podemos observar que, da mesma forma que no método AHP, eles obtêm notas excelentes, com valores de 5, tanto a Matemática quanto a Português. Essas notas refletem as suas capacidades, e satisfação com os resultados do seu desempenho. Além disso, esses alunos demonstram um bom envolvimento nas atividades escolares. Por fim, é notável que todos esses alunos pertencem aos grupos calculados como de baixo risco.

Análise do método SAW

Este método, ao contrário do AHP e do EWM, utiliza os valores da tabela 12 como vetor de peso dos critérios.

Os resultados deste método são a seguir apresentados:

Tabela 22: Resultados alunos Alto Risco- SAW

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 259	2	2	1	1	18	0
Id 496	2	2	2	1	12	0
Id 800	2	2	2	1	18	0
Id 113	2	2	2	1	17	0
Id 492	2	2	2	1	18	0

Tabela 23: Resultados alunos Baixo Risco - SAW

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 651	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 64	5	5	5	5	25	3
Id 199	5	5	5	5	25	3
Id 743	5	5	5	5	25	3

No que diz respeito às alternativas, podemos tirar as mesmas conclusões que no método AHP. Os alunos com maior risco de insucesso escolar têm notas baixas, com valores de 2 tanto a Português quanto a Matemática. Além disso, eles são atribuídos ao Cluster 0, que representa o nível 1, considerado de alto risco.

No critério Notas esses alunos têm um valor de 1, refletindo suas capacidades.

Por fim, em relação à satisfação com as notas, essa varia entre 1 e 2, ambos com valores negativos. Isso indica que esses alunos não estão satisfeitos com suas notas. Quanto ao envolvimento, varia de 12 a 18, demonstrando uma baixa participação e falta de envolvimento em atividades escolares.

Em relação aos alunos de baixo risco, podemos observar que, da mesma forma que no método AHP, eles obtêm notas excelentes, com valores de 5, tanto a Matemática quanto a Português. Essas notas refletem suas capacidades, e eles estão satisfeitos com o seu desempenho. Além disso, esses alunos

demonstram um excelente envolvimento nas atividades escolares. Por fim, é notável que todos esses alunos pertencem aos grupos calculados como de baixo risco.

Esses dados estão em conformidade com o estudo realizado para a atribuição dos perfis de risco ou clusters dos alunos, como evidenciado na Tabela 6.

Análise do método TOPSIS

No método TOPSIS, sendo um método de classificação de alternativas, é necessário fornecer desde o início um vetor de pesos para os critérios e o impacto que eles têm no problema. Ambos podem ser observados na Tabela 12. Este método foi aplicado seguindo os procedimentos descritos na secção 2.3.

Os resultados obtidos podem ser vistos a seguir:

Tabela 24: Resultados alunos Alto Risco - TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 248	2	2	2	1	16	0
Id 259	2	2	1	1	18	0
Id 113	2	2	2	1	17	0
Id 492	2	2	2	1	18	0

Tabela 25: Resultados alunos Baixo Risco - TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 199	5	5	5	5	25	3
Id 64	5	5	5	5	25	3
Id 651	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 743	5	5	5	5	25	3

Como podemos observar, os alunos de alto risco são essencialmente identificados por terem notas de Português e Matemática negativas, 2 valores, e valores de 1 nas suas notas. O nível de satisfação varia em 1 e 2 e o envolvimento varia entre os valores 12 e 18. Todos os alunos pertencem ao *cluster* 0, que identifica os alunos em alto risco.

Os alunos de baixo risco por sua vez apresentam notas de 5 valores a ambas as disciplinas bem como a nível de satisfação e as suas notas. O seu envolvimento na escola é muito elevado, no valor dos 25 e o seu *cluster* é o 3, que representa o grupo de alunos de baixo risco de insucesso.

Análise do método MOORA

O método MOORA obteve resultados semelhantes aos do método TOPSIS, com algumas pequenas diferenças na ordem das alternativas. Isso ocorreu porque os conjuntos de critérios e os pesos atribuídos a esses critérios eram os mesmos, tornando redundante a explicação dos resultados obtidos. As diferenças na ordem das alternativas surgem das diferentes abordagens de cálculo aplicadas a elas.

Tabela 26: Resultados alunos Alto Risco- MOORA

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 259	2	2	1	1	18	0
Id 248	2	2	2	1	16	0
Id 113	2	2	2	1	17	0
Id 492	2	2	2	1	18	0

Tabela 27: Resultados alunos Baixo Risco - MOORA

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 743	5	5	5	5	25	3
Id 64	5	5	5	5	25	3
Id 199	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 651	5	5	5	5	25	3

Tanto no método MOORA, como no método TOPSIS, os resultados estão em conformidade com o estudo realizado para a atribuição dos perfis de risco ou *clusters* dos alunos, como evidenciado na Tabela 6.

Análise do método SAW-TOPSIS

Após a análise dos métodos e de sua performance individual, também foram examinados os desempenhos de métodos híbridos, como SAW-TOPSIS, AHP-TOPSIS, AHP-MOORA, EWM-TOPSIS e EWM-MOORA.

Conforme mencionado anteriormente, o método SAW não é um método de classificação, uma vez que não envolve a categorização de dados em classes predefinidas. Em vez disso, concentra-se na comparação e classificação de alternativas com base nas suas pontuações agregadas.

Assim, o método SAW-TOPSIS combina as vantagens de ambos os métodos. O SAW pode ser usado para atribuir pesos aos critérios e obter valores ponderados iniciais para as alternativas, enquanto o TOPSIS é utilizado para lidar com a diversidade entre as alternativas e obter uma classificação final mais robusta.

Com base nisso, os valores obtidos para o dataset usando ambos os modelos são os seguintes:

Tabela 28: Resultados alunos Alto Risco- SAW-TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 259	2	2	1	1	18	0
Id 496	2	2	2	1	12	0
Id 113	2	2	2	1	17	0
Id 248	2	2	2	1	16	0
Id 800	2	2	2	1	18	0

Tabela 29: Resultados alunos Baixo Risco - SAW-TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 651	5	5	5	5	25	3
Id 743	5	5	5	5	25	3
Id 199	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 64	5	5	5	5	25	3

Podemos observar que os resultados obtidos para os alunos de alto risco são diferentes dos resultados obtidos nos modelos individuais. As diferenças nos resultados ocorrem devido às abordagens distintas e aos princípios subjacentes de cada método, por exemplo enquanto que no método individual SAW as pontuações ponderadas são somadas para cada alternativa, fornecendo uma avaliação direta das

alternativas em relação aos critérios, no método TOPSIS, as pontuações são usadas para calcular as distâncias até os pontos ideais e anti-ideais, resultando em uma análise comparativa das alternativas.

Outro motivo será as diferentes equações de normalização utilizadas.

Ainda assim, podemos realizar uma análise dos valores obtidos de forma semelhante àquela realizada para os modelos individuais. Os alunos que fazem parte deste grupo de risco mantêm notas de 2 valores, tanto a Português quanto a Matemática, e pertencem ao Cluster 0. As suas notas também permanecem com valor de 1.

Por outro lado, os alunos de baixo risco mantêm características semelhantes às atribuídas nos métodos individuais.

Assim uma combinação dos métodos SAW e TOPSIS no método híbrido SAW-TOPSIS aproveita as vantagens de ambos os métodos e compensa as suas limitações individuais.

Análise do método AHP-TOPSIS

Como discutido anteriormente, o método AHP é um método de atribuição de pesos que oferece um processo transparente para a atribuição de pesos aos critérios, envolvendo a avaliação de comparações pareadas. Isso ajuda a reduzir a subjetividade do problema em questão.

No entanto, o método AHP por si só não é adequado para a classificação de alternativas, o que justifica a utilização do método TOPSIS.

O método AHP-TOPSIS, portanto, procura auxiliar o método AHP na fase de classificação e auxiliar o método TOPSIS na atribuição de pesos aos critérios. Em essência, esse método híbrido permite tirar proveito das vantagens de ambos os métodos.

O AHP, além de fornecer um vetor de pesos por meio de um processo transparente, também capta as relações entre os critérios e como eles se influenciam mutuamente.

A combinação de AHP-TOPSIS aproveita a estrutura hierárquica do AHP e a avaliação comparativa do TOPSIS, resultando num processo de tomada de decisão mais robusto e informado.

Em suma, o método combinado AHP-TOPSIS permite uma abordagem estruturada e hierárquica para avaliar a importância dos critérios e, ao mesmo tempo, classificar as alternativas de acordo com sua similaridade às soluções ideais. Este ajuda a abordar tanto a complexidade dos critérios quanto a diversidade entre as alternativas, levando a uma tomada de decisão mais abrangente e bem fundamentada.

Com isto, os valores obtidos para o dataset utilizando ambos os modelos foi a seguinte:

Podemos observar que os resultados obtidos para os alunos de alto risco são bastante semelhantes aos resultados obtidos no método TOPSIS.

Tabela 30: Resultados alunos Alto Risco- AHP-TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 248	2	2	2	1	16	0
Id 259	2	2	1	1	18	0
Id 113	2	2	2	1	17	0
Id 800	2	2	2	1	18	0

Tabela 31: Resultados alunos Baixo Risco - AHP-TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 61	5	5	5	5	25	3
Id 743	5	5	5	5	25	3
Id 199	5	5	5	5	25	3
Id 64	5	5	5	5	25	3
Id 651	5	5	5	5	25	3

Isto tem como base o fato de que os pesos atribuídos aos critérios foram distribuídos de forma semelhante àquela inicialmente atribuída para o método TOPSIS.

No entanto, os resultados não foram tão semelhantes aos apresentados pelo AHP. Isso ocorre porque o método de "classificação" utilizado pelo AHP foi o SAW, que, como discutido anteriormente, não leva em consideração as soluções ideais para o problema.

Ou seja, a nível de valores temos que os alunos de alto risco permanecem com notas de 2 valores, tanto a Português como a Matemática, e pertencem ao *cluster* 0. As suas notas também mantêm-se no valor 1. O seu envolvimento escolar varia entre 12 e 18 e a satisfação com as notas entre 1 e 2.

Mais uma vez, os alunos de baixo risco mantêm-se com características iguais aos atribuídos nos métodos individuais.

Análise do método AHP-MOORA

Outro método que podia ser integrado com o AHP para classificação das alternativas é o método estudado MOORA.

Como referido anteriormente, MOORA é uma técnica de otimização que considera múltiplos objetivos e ajuda a classificar alternativas em relação a esses objetivos. Avalia assim o desempenho de cada

Tabela 32: Resultados alunos Alto Risco- AHP-MOORA

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 259	2	2	1	1	18	0
Id 248	2	2	2	1	16	0
Id 113	2	2	2	1	17	0
Id 492	2	2	2	1	18	0

Tabela 33: Resultados alunos Baixo Risco - AHP-MOORA

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 199	5	5	5	5	25	3
Id 651	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 743	5	5	5	5	25	3
Id 64	5	5	5	5	25	3

alternativa em relação aos objetivos, tendo em consideração as relações de vantagem e desvantagem.

Ou seja, o AHP oferece um método transparente para atribuição de pesos e o MOORA avalia as alternativas em relação aos objetivos, permitindo uma análise comparativa e uma classificação das alternativas com base nos desempenhos em relação aos critérios. A combinação AHP-MOORA aproveita assim a estruturação hierárquica do AHP e a análise de múltiplos objetivos do MOORA, resultando em uma análise mais completa e abrangente.

Com isto, os valores obtidos para o dataset utilizando ambos os métodos foi a seguinte:

Os resultados são semelhantes aos dos obtidos no método MOORA pelo mesmo motivo que em AHP-TOPSIS. Ou seja, os valores do vetor peso obtidos no método AHP distribuem a importância relativa dos critérios como o vetor peso atribuído inicialmente ao método MOORA.

Análise do método EWM-TOPSIS

Tal como discutido anteriormente o método EWM caracteriza-se pelo uso do cálculo da entropia para obter o vetor de pesos dos critérios do problema. Ele é, por si só, um método de atribuição de pesos e não de classificação de alternativas.

Portanto, a combinação dos métodos EWM-TOPSIS oferece uma maneira imparcial de atribuir pesos

aos critérios com base na distribuição da entropia, evitando a subjetividade típica desse processo. Ao mesmo tempo, o método TOPSIS avalia as alternativas em relação aos critérios, permitindo uma análise comparativa e uma classificação das alternativas com base nas sua similaridade com soluções ideais.

Com base nisso, os valores obtidos para o dataset aplicando ambos os modelos são os seguintes:

Tabela 34: Resultados alunos Alto Risco- EWM-TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 703	3	3	1	1	12	0
Id 721	4	4	5	4	20	3
Id 436	3	3	1	1	18	0
Id 418	3	3	3	4	15	1

Tabela 35: Resultados alunos Baixo Risco - EWM-TOPSIS

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 199	5	5	5	5	25	3
Id 651	5	5	5	5	25	3
Id 64	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 743	5	5	5	5	25	3

Os resultados obtidos para o grupo de alunos de alto risco são bastante diferentes daqueles obtidos para qualquer um dos métodos aplicados individualmente.

Aqui os pesos obtidos pelo EWM são usados para ponderar os critérios na análise do TOPSIS, onde as alternativas são classificadas de acordo com a sua similaridade às soluções ideais e anti-ideais em relação aos critérios.

Podemos observar que as notas variam de 2 a 4 tanto a Português como a Matemática, sendo que 3 e 4 são notas satisfatórias para estarem a ser consideradas como índice de risco de insucesso escolar.

O que podemos concluir é que, uma vez que os pesos ou a importância dos critérios estão distribuídos quase uniformemente entre eles, isso não reflete a realidade das preferências ou importâncias dos *stakeholders*. Isso leva a uma equalização artificial das contribuições dos critérios para a decisão. Em resumo, o método EWM, ao atribuir pesos quase iguais aos critérios, suprime a diferenciação entre as

alternativas nos resultados finais, uma vez que os critérios são tratados como igualmente relevantes. Isso torna complexa a distinção entre alunos em alto ou médio risco, uma vez que não há uma clara distinção entre quais critérios apresentam maior peso.

Assim, quando esses pesos são usados no método EWM-TOPSIS para classificar alternativas, as mesmas vão ser classificadas com base em critérios que se consideram igualmente importantes, o que leva a que os resultados não reflitam a realidade das preferências dos *decision makers* nem a realidade do contexto do problema.

Análise do método EWM-MOORA

O EWM-MOORA combina a atribuição de pesos do EWM com a otimização multi-objetivo do MOORA. Os pesos obtidos pelo EWM são usados para ponderar os critérios na análise do MOORA, que avalia as alternativas em relação a múltiplos objetivos e classifica as alternativas com base nessas avaliações.

Aquando da utilização do método EWM com o método MOORA, os resultados apresentam-se diferentes, mas ligeiramente mais satisfatórios do que o método EWM-TOPSIS, conforme podemos observar a seguir:

Tabela 36: Resultados alunos Alto Risco- EWM-MOORA

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 496	2	2	2	1	12	0
Id 259	2	2	1	1	18	0
Id 721	4	2	1	1	8	0
Id 248	2	2	2	1	16	0
Id 113	2	2	2	1	17	0

Tabela 37: Resultados alunos Baixo Risco - EWM-MOORA

Identificação do Aluno	Nota Pt.	Nota Mat.	Autoaval.	Notas	Envolvimento	Cluster
Id 199	5	5	5	5	25	3
Id 61	5	5	5	5	25	3
Id 743	5	5	5	5	25	3
Id 651	4	5	5	3	23	3
Id 64	5	5	5	5	25	3

A melhoria observada neste processo decorre do fato de que o TOPSIS utiliza os pesos obtidos no método EWM para calcular as soluções ideais e, com base nesses cálculos, classificar as alternativas com base nas suas distâncias em relação a essas soluções. Uma vez que os pesos atribuídos pelo EWM não refletem as preferências dos *stakeholders*, isso explica por que os resultados não são satisfatórios.

Porem, o EWM-MOORA leva em consideração a otimização multi-objetivo, o que é útil quando existem múltiplos objetivos conflitantes ou complementares. Se a decisão envolve equilibrar várias metas e prioridades, o EWM-MOORA pode ser mais adequado, pois ele procura encontrar alternativas que sejam otimizadas em relação a vários critérios ao mesmo tempo.

O método EWM-MOORA utiliza a otimização multi-objetivo do MOORA para analisar e classificar as alternativas em relação a vários objetivos. Isso leva a uma consideração mais abrangente das metas dos *stakeholders* e resulta numa classificação que se alinham melhor com as expectativas, mesmo que os pesos dos critérios do EWM não estejam ideais.

Relativamente aos valores observados, temos que todos os alunos pertencem ao cluster 0, que representa um alto nível de risco, além disso as notas a Português e Matemática obtêm numa média de 2 valores, bem como a satisfação com as notas. As notas dos alunos são de 1 valor e por fim o seu envolvimento é baixo, numa média de 14 valores.

A nível dos alunos de baixo risco temos de uma forma geral valores máximos para todos os critérios, ou seja excelentes notas tanto a Português como a Matemática, satisfação, notas e envolvimento alto, e classificação no cluster 3 que representa baixo risco de insucesso escolar.

4.3.2 Discussão dos resultados

Tabela 38: Ranking dos alunos de alto risco

AHP	EWM	SAW	TOPSIS	MOORA
Id 496	Id 453	Id 259	Id 496	Id 496
Id 248	Id 721	Id 496	Id 248	Id 259
Id 259	Id 418	Id 800	Id 259	Id 248
Id 113	Id 496	Id 113	Id 113	Id 113
Id 814	Id 412	Id 492	Id 492	Id 492

Os resultados obtidos, conforme podemos observar na Tabela 38, são bastante semelhantes entre os métodos individuais, com exceção do método EWM. Além disso, podemos constatar que, de uma

forma geral, todos os resultados são bastante satisfatórios e estão de acordo com o quadro de referência apresentado na Tabela 6.

Os métodos AHP, TOPSIS e MOORA apresentam resultados bastante semelhantes, principalmente porque os pesos ou importâncias atribuídos aos critérios de seleção são similares. No entanto, ainda podemos observar algumas diferenças no ranking, o que reflete a conclusão mencionada anteriormente de que o método AHP não procura as soluções ideais nem a sua otimização.

Além disso o método AHP e SAW apresentam também aproximações entre eles, apesar de a ordem dos alunos de maior risco não ser igual. Isso ocorre porque a ordem das alternativas reflete a importância dos pesos atribuídos aos critérios. Nesse caso, o método AHP atribui um valor mais alto às notas dos alunos, tornando-a o principal critério de seleção nas escolhas das alternativas, seguida pelo cluster ao qual pertencem. No método SAW, embora a distribuição das importâncias seja semelhante, difere ligeiramente, atribuindo menos importância às notas e um pouco mais ao cluster.

O método EWM obteve os piores resultados, como já explicado, devido à atribuição de pesos de forma praticamente uniforme, o que resultou em resultados que não representavam adequadamente a realidade.

Numa análise mais a fundo, a entropia é uma medida da incerteza num conjunto de dados. Quanto maior a entropia de uma variável, menos informações distintas ela fornece, e, portanto, menos peso é lhe atribuído. Neste método, a distribuição de pesos faz com que quanto menor a entropia, maior a pontuação de utilidade e, conseqüentemente, maior o peso atribuído. Tendo isto em consideração, é possível verificar que o mesmo se reflete no conjunto de dados, uma vez que o atributo que recebeu o maior peso é o envolvimento escolar, devido à sua ampla variação de informações distintas, com valores entre 5 e 25. Por outro lado, os restantes atributos apresentam variações muito mais limitadas, com valores entre 1 e 5, ou 0 e 4 no caso do cluster. Isso resulta em pesos atribuídos tão semelhantes e baixos, uma vez que os dados disponíveis não demonstram uma variação significativa na entropia das variáveis, tornando difícil discernir a importância relativa dos critérios com base na medida de entropia.

Portanto, podemos concluir que, em termos de métodos individuais, os melhores resultados foram obtidos para o AHP, SAW, TOPSIS e MOORA. No entanto, uma vez que os métodos TOPSIS e MOORA não são métodos de ponderação de pesos, os métodos mais eficazes são o AHP e o SAW.

O método SAW apresenta a desvantagem da subjetividade na atribuição prévia de pesos por parte dos *stakeholders*, enquanto o AHP é mais robusto. Além disso, o AHP permite avaliar a consistência dos pesos, o que ajuda a identificar inconsistências nas escolhas subjetivas.

Portanto, podemos concluir que o método AHP é o mais apropriado para o tipo de dados a ser tratado e para o contexto do problema em questão.

Assim, e através de uma observação mais direta sobre os alunos/alternativas selecionados como os Top5 alunos em maior risco de insucesso escolar, podemos observar que o AHP representa de forma mais próxima da realidade aquilo que se espera encontrar num aluno identificado no cluser 0.

Tabela 39: Ranking dos alunos de alto risco

AHP-TOPSIS	AHP-MOORA	EWM-TOPSIS	EWM-MOORA	SAW-TOPSIS
ld 496	ld 496	ld 496	ld 496	ld 259
ld 248	ld 259	ld 703	ld 259	ld 496
ld 259	ld 248	ld 721	ld 721	ld 113
ld 113	ld 113	ld 436	ld 248	ld 248
ld 800	ld 492	ld 418	ld 113	ld 800

Relativamente aos métodos híbridos, temos que, AHP-TOPSIS e AHP-MOORA apresentam melhores resultados, seguindo o método híbrido SAW-TOPSIS e EWM-MOORA, sendo os piores resultados obtidos com o método EWM-TOPSIS.

O método AHP-TOPSIS e o método SAW-TOPSIS apresentam resultados idênticos a nível dos TOP5 alunos em risco de insucesso escolar. O método AHP-MOORA e EWM-MOORA, apresentam resultados igualmente semelhantes.

A utilização dos métodos híbridos justifica-se pelo uso apropriado dos métodos na sua devida área de atuação, procurando usufruir das vantagens de ambos os métodos e amenizar as suas desvantagens. Assim, os métodos AHP, EWM e SAW, forma usados como métodos de ponderação de pesos usufruindo das suas vantagens a nível de robustez e baixa subjetividade e o métodos TOPSIS e MOORA como métodos de classificação usufruindo das suas eficiências computacionais, escalabilidade e facilidade de compreensão dos resultados.

Usar métodos de ponderação de pesos e de classificação como apoio a tomadas de decisão multi-critério permite não só uma maior qualidade de decisão como também uma decisão mais objetiva, uma vez que os métodos de ponderação ajudam na quantificação da importância dos critérios e os métodos de classificação aplicam essas ponderações de forma consistente para avaliar as alternativas. É ainda uma forma de automatizar o processo de tomada de decisão o que o torna mais eficiente e menos suscetível a erros e *bias*.

Conforme podemos observar na Tabela 39, e com base nas tabelas discutidas na secção anterior, podemos averiguar que as variações dos métodos AHP, AHP-TOPSIS e AHP-MOORA, bem como o SAW-TOPSIS são os que apresentam um melhor quadro de alunos de alto risco de insucesso escolar.

O método EWM-TOPSIS apresenta os piores resultados, pois como já foi anteriormente referido, os valores das soluções ideias usadas pelo método TOPSIS são enviesadas pelo mau desempenho e errada distribuição de pesos obtida através do método EWM.

O método EWM-MOORA, apesar de ter minimizado o impacto negativo do método EWM através da vantagem inerente do método MOORA para procurar otimizar a busca das alternativas, permanece com algumas alternativas que não representam de forma verdadeira o contexto do problema.

No entanto, apesar dos resultados positivos obtidos por parte do método SAW e a sua junção com métodos de classificação, os métodos que utilizam AHP continuam a ser preferencial uma vez que o método SAW continua a não ser uma alternativa viável para o tipo de problema em questão, uma vez que exige uma pré-distribuição dos pesos tornando os resultados muito subjetivos.

Portanto, podemos concluir que, em termos de métodos individuais, o método AHP é o mais eficaz, enquanto que, no caso dos métodos híbridos, o método AHP e as suas variações se destacam como os mais adequados para a identificação dos alunos em alto risco de insucesso escolar.

Em geral, podemos notar que os métodos classificam os dados levando em consideração o critério de maior importância. Quando o maior peso é atribuído às notas das disciplinas, os resultados são bastante semelhantes, enquanto que, quando o peso mais significativo é dado a outro critério, como o envolvimento, como ocorre no método EWM, os resultados apresentam mudanças substanciais.

No entanto, e em forma de conclusão, os resultados obtidos são bastante intuitivos, já que faz sentido que os alunos com notas mais baixas a matemática e português sejam considerados de alto risco, especialmente quando combinado com um baixo envolvimento escolar. Da mesma forma, é compreensível que os alunos de baixo risco alcancem notas excelentes a português e matemática, juntamente com um elevado envolvimento escolar.

Capítulo 5

Conclusões e trabalho futuro

Ao longo deste documento, abordei o problema da identificação precoce de alunos em risco de insucesso escolar, com o objetivo de promover a implementação de ações rápidas e eficazes de apoio a esses alunos. O trabalho foi desenvolvido em várias etapas, envolvendo revisões de literatura, análise de dados e a aplicação de modelos de análise preditiva e métodos multi-critério para apoio à tomada de decisão.

A revisão da literatura desempenhou um papel crucial no meu estudo, onde explorei os modelos de análise preditiva mais amplamente utilizados no contexto educacional para prever o nível de risco dos alunos. Também conduzi uma revisão sobre os métodos multi-critério para apoio à tomada de decisão no mesmo contexto. Isso proporcionou um amplo entendimento das abordagens existentes e as suas respectivas vantagens e limitações.

Uma das principais conclusões retiradas na minha pesquisa foi que não existe um único conjunto específico de dados que devem ser utilizados para resolver este problema, no entanto, observei que, dados relacionados a notas, presenças em aula e informações pessoais, como situação financeira e grau de escolaridade dos encarregados de educação, são recorrentes em muitos estudos. Essa observação destacou a importância desses atributos como indicadores-chave para identificar alunos em risco de insucesso escolar.

Além disso, ao aplicar vários modelos de análise preditiva e métodos multi-critério ao meu conjunto de dados, constatei que o modelo XGBoost se destacou como o mais eficaz para prever o risco de insucesso escolar. Em paralelo, o método AHP-TOPSIS demonstrou ser altamente eficiente na tomada de decisões multi-critério, permitindo a classificação e ordenação dos alunos em risco com base em múltiplos critérios relevantes.

Por fim, obtive uma lista ordenada de alunos em maior risco de insucesso escolar, acompanhada pelos dados que englobam essa classificação. Essa lista representou uma contribuição significativa para a resolução do problema central da minha tese, fornecendo às instituições educacionais uma base sólida para a implementação de medidas preventivas e personalizadas de apoio aos alunos mais vulneráveis.

Em suma, a minha pesquisa abordou a identificação de alunos em risco de insucesso escolar, combinando revisões de literatura, análise de dados e a aplicação de modelos de análise preditiva e métodos multi-critério. Os resultados destacaram a importância dos dados relevantes e a eficácia do modelo XGBoost e do método AHP-TOPSIS na resolução desse desafio educacional.

5.1 Questões de investigação

5.1.1 Que modelos de machine learning obtém melhores resultados na área da educação ?

Como evidenciado pela revisão da literatura, não existe uma resposta única e definitiva para esta questão, uma vez que a escolha do modelo mais apropriado depende de diversos fatores, incluindo a natureza do problema em questão, os objetivos da análise e o tipo de dados disponíveis.

No entanto, ao examinarmos a literatura e após um estudo aprofundado, identificamos que os modelos preditivos mais amplamente utilizados na identificação do desempenho dos alunos na área da educação incluem *Decision Trees*, *Random Forests* e algoritmos de *Boosting*. Esses modelos têm se mostrado eficazes na análise de dados educacionais para prever o desempenho dos alunos e identificar riscos associados ao sucesso académico.

No contexto específico do nosso caso de estudo, conduzimos uma análise detalhada de modelos de análise preditiva, incluindo o *Hybrid Random Forest*, *Decision Tree*, *XGBoost*, *Gradient Boost* e *Adaboost*. Dentre esses modelos, o XGBoost destacou-se ao apresentar um desempenho superior em relação aos restantes. Ele demonstrou, de uma forma geral, as melhores métricas, alcançando uma *accuracy* de 99%, tornando-o o modelo ideal para usar com este tipo de conjunto de dados. Além deste, o Hybrid Random Forest demonstrou um desempenho bastante satisfatório, classificando-se como o segundo melhor modelo em termos de métricas globais.

Ao utilizar todas as seis características do conjunto de dados, que englobam resultados de avaliações de Português e Matemática no segundo trimestre, a satisfação do aluno com seu próprio desempenho, as avaliações feitas pelos alunos e a pontuação total de envolvimento na escola, o XGBoost permitiu-nos determinar com precisão o nível de risco para cada aluno. Isso significa que podemos identificar tanto alunos em alto risco quanto aqueles em baixo risco com um alto nível de confiança, o que é crucial para intervenções e estratégias de ensino personalizadas.

Portanto, com base nesta pesquisa e análise de dados, concluímos que o modelo XGBoost é altamente

eficaz na área da educação, especialmente para a identificação do desempenho dos alunos e a avaliação do risco acadêmico. No entanto, ressalto que a escolha do modelo deve sempre ser feita com base no contexto e características do problema, bem como nos dados disponíveis, sendo sempre necessário considerar cuidadosamente o contexto de cada situação educacional.

5.1.2 Que métodos multi-critério de apoio à tomada de decisão obtém melhores resultados na área da educação ?

Tal como acontece com os modelos preditivos, não existe uma única resposta definitiva para esta questão, uma vez que a escolha do método apropriado depende de vários fatores, incluindo os objetivos específicos da análise e o tipo de dados disponíveis.

A revisão da literatura revela que, na área da educação, diversos métodos multi-critério têm sido aplicados com sucesso. Entre os métodos mais amplamente utilizados estão o Simple Additive Weighting (SAW) e o Analytic Hierarchy Process (AHP) como métodos de atribuição de pesos, e o Technique for Order of Preference by Similarity to Ideal Solution (TOPSIS) como método de classificação. Além disso, métodos híbridos, que combinam dois ou mais métodos multi-critério, também têm sido amplamente estudados neste contexto educacional.

No que diz respeito ao caso de estudo, conduzimos análises utilizando os métodos AHP, SAW, Entropy Weight Method (EWM), TOPSIS e Multi-Objective Optimization by Ratio Analysis (MOORA). Além disso, exploramos conjuntos híbridos que combinaram os diferentes métodos de atribuição de pesos com os diferentes métodos de classificação.

Observamos que, para o conjunto de dados disponíveis, o método AHP demonstrou um desempenho superior na atribuição de pesos. Isto deve-se ao fato de que o AHP, não apenas refletiu as preferências dos *decision makers*, mas também representou adequadamente o domínio em questão.

Os métodos TOPSIS e MOORA também apresentaram bons resultados quando aplicados individualmente, mas não refletiam a realidade uma vez que implicava uma atribuição a priori e subjetiva dos pesos aos critérios.

No entanto, o desempenho mais robusto foi alcançado por meio dos métodos híbridos, especificamente o híbrido entre AHP e TOPSIS, bem como o híbrido entre AHP e MOORA. Esses métodos híbridos demonstraram a capacidade de otimizar a tomada de decisão e fornecer resultados mais abrangentes e confiáveis.

Portanto, com base nesta pesquisa, concluímos que, no contexto específico deste caso de estudo, os métodos multi-critério AHP, TOPSIS e MOORA, especialmente em forma híbrida, são altamente eficazes

para apoiar a tomada de decisão na área da educação.

5.1.3 Que vantagens se podem obter dos sistemas de apoio à decisão na educação ?

Os sistemas de apoio à decisão (SAD) na educação têm demonstrado um potencial notável para oferecer uma série de vantagens cruciais para a melhoria do ensino e aprendizagem.

Primeiramente, e como foi objetivo deste projeto, eles são uma possível ferramenta para a identificação precoce de alunos com dificuldades académicas através da análise de uma variedade de dados académicos e comportamentais. Este é um ponto crucial que abre caminho para a implementação de ações mais significativas, como intervenções personalizadas, a fim de prevenir o impacto negativo no desempenho dos alunos.

Essas intervenções personalizadas são uma das principais vantagens dos SAD, já que os educadores podem adaptar as suas abordagens de ensino e oferecer um suporte mais direcionado para ajudar os alunos a superar obstáculos específicos.

Como resultado, as taxas de insucesso e abandono escolar são minimizadas, pois os alunos recebem o apoio de que precisam para ter sucesso. Além disso, os SAD podem ainda auxiliar na alocação eficiente de recursos, garantindo que os recursos educacionais sejam direcionados para os casos que mais necessitam.

Além disso, estes sistemas permitem o monitoramento contínuo do desempenho educacional, fornecendo informações valiosas para avaliar a eficácia das políticas educacionais e fazer ajustes com base em dados reais.

Em resumo, os sistemas de apoio à tomada de decisão na educação são ferramentas poderosas que contribuem para o sucesso dos alunos, reduzem as taxas de insucesso e abandono escolar, promovem a eficiência na alocação de recursos e possibilitam a melhoria contínua do sistema educacional. Essas vantagens são fundamentais para alcançar a excelência educacional e a igualdade de oportunidades para todos os alunos.

5.2 Disseminação de resultados

Após a participação na conferência *1st International Conference on Data Science & Artificial Intelligence*, que ocorreu nas datas 27 a 30 de Novembro de 2022, foi apresentado o artigo:

- Jordão, S., Durães, D., & Novais, P. (2023). *Performance Analysis of Models Used to Predict*

Failure in Secondary School. In Data Science and Artificial Intelligence. LNCS Springer International Publishing.

Embora já tenha sido aceite para publicação, este artigo ainda não foi publicado, o que acontecerá em breve.

O objetivo principal deste artigo foi investigar um caso de estudo cujo propósito era identificar os modelos mais eficazes para prevenir o insucesso no ensino secundário. Após a realização do pré-processamento dos dados, foram aplicados cinco modelos de *machine learning*: Random Forest, Decision Tree, XGBoost, Gradient Boosting e ADA Boost. Estes modelos foram comparados e analisados os resultados obtidos. Após a análise, concluímos que o modelo XGBoost se destacou, apresentando os resultados mais promissores em termos de *accuracy* na previsão do insucesso escolar.

Além disso, neste artigo foram discutidas perspetivas para trabalhos futuros. Assim, com base no nível de risco identificado para cada aluno, planeamos desenvolver um modelo de apoio à tomada de decisão que permita a geração de alertas, os quais poderão ser direcionados a professores, pais e/ou psicólogos, dependendo do nível de risco específico identificado para cada estudante. Esta abordagem procura contribuir significativamente para a prevenção do insucesso no ensino secundário, ao fornecer um sistema de alerta precoce para intervenções direcionadas.

5.3 Perspetiva de trabalho futuro

As perspetivas de trabalho futuro para esta pesquisa são promissoras e podem ser divididas em duas direções principais.

Primeiramente, uma direção menos complexa envolve o desenvolvimento de uma interface que permita aos utilizadores finais não apenas visualizar os resultados, mas também introduzir dados diretamente no conjunto de dados. Isso proporcionaria uma experiência mais interativa e eficiente, permitindo que administradores educacionais e outros profissionais adicionem informações em tempo real.

Uma perspetiva mais ambiciosa envolve a implementação deste sistema numa escola real. Nesse contexto, os professores teriam a capacidade de inserir os dados dos alunos e aplicar o sistema para identificar precocemente aqueles em risco de insucesso escolar. Isto possibilitaria a intervenção mais rápida e eficaz para apoiar esses alunos. Seria ainda interessante integrar o sistema desenvolvido a sistemas já em uso na instituição escolar, agregando assim um maior conjunto de dados.

No futuro, o sistema também poderia ser utilizado como base para o desenvolvimento de técnicas de apoio personalizadas aos alunos em risco, envolvendo a criação de estratégias individualizadas com base

nos dados do aluno e nas informações fornecidas pelo sistema, visando não apenas a identificação, mas também a implementação de ações específicas para melhorar o desempenho e a taxa de retenção dos alunos.

Estas perspectivas de trabalho futuro destacam o potencial contínuo de aprimoramento e aplicação prática do sistema desenvolvido, com o objetivo de contribuir de maneira significativa para a redução das taxas de abandono e insucesso escolar, bem como para o aprimoramento da qualidade da educação.

Bibliografia

Artificial intelligence, machine learning, and deep learning: Same context, different concepts, 2018.

Ai, ml and dl: What's the difference? <https://www.opensourceforu.com/2022/08/ai-ml-and-dl-whats-the-difference/>, 2022.

Mesran Aan, Rivalri Hondro, Muhammad Syahrizal, Andysah Putera Utama Siahaan, Robbi Rahim, and Suginam Gienam. Student admission assessment using multi-objective optimization on the basis of ratio analysis (moora). *Journal Online Jaringan COT POLIPD (JOJAPS)*, 10:2–6, 10 2017.

Gabriela Leal Redigolo Patrícia Jaqueline Arakaki Paulo Sergio Felix da Silva Alan Cesar, Belo Angeluci. Design science research como método para pesquisas em tdc na educação design science research as method for icdt in education research, 2020.

Veeris Ammarapala, Thanwadee Chinda, Pimnapa Pongsayaporn, Wit Ratanachot, Koonnamas Punthutaecha, and Koson Janmonta. Cross-border shipment route selection utilizing analytic hierarchy process (ahp) method. *Songklanakarin Journal of Science and Technology*, 40, 03 2018. doi: 10.14456/sjst-psu.2018.3.

Dini Anggraini and Hengki Tamando Sihotang. Decision support system for choosing the best class guardian with simple additive weighting method. 2019.

Hambali Ariff, S. Sapuan, Napsiah Ismail, and Nukman Yusoff. Use of analytical hierarchy process (ahp) for selecting the best design concept. *Jurnal Teknologi*, 49:1–18, 12 2008. doi: 10.11113/jt.v49.188.

Yufika Sari Bagi, Suyono Suyono, and Michel Farrel Tomatala. Decision support system for high achieving students selection using ahp and topsis. 2020. ISBN 9781728172576. doi: 10.1109/ICORIS50180.2020.9320823.

Olga Blasco-Blasco, Marina Liern-García, Aarón López-García, and Sandra E. Parada-Rico. An academic performance indicator using flexible multi-criteria methods. 9, 2021. ISSN 22277390. doi: 10.3390/math9192396.

- Aleksandra Bączkiewicz, Jarosław Wątróbski, Bartłomiej Kizielewicz, and Wojciech Sałabun. Towards objectification of multi-criteria assessments: a comparative study on mcda methods. pages 417–425, 09 2021. doi: 10.15439/2021F61.
- Tatiana Cardona, Elizabeth A. Cudney, Roger Hoerl, and Jennifer Snyder. Data mining and machine learning retention models in higher education. *Journal of College Student Retention: Research, Theory & Practice*, 2016. doi: 10.1177/1521025120964920.
- Tatiana A Cardona. Development of a system architecture for the prediction of development of a system architecture for the prediction of student success using machine learning techniques student success using machine learning techniques, 2020.
- Davide Carneiro, Paulo Novais, Dalila Durães, José Miguel Pego, and Nuno Sousa. Predicting completion time in high-stakes exams. *Future Generation Computer Systems*, pages 549–559, 2019. ISSN 0167739X. doi: 10.1016/j.future.2018.01.061.
- CFI Team. Decision Support System (DSS). <https://corporatefinanceinstitute.com/resources/management/decision-support-system-dss/>.
- Shankar Chakraborty. Applications of the moora method for decision making in manufacturing environment. *International Journal of Advanced Manufacturing Technology*, 54:1155–1166, 06 2011. doi: 10.1007/s00170-010-2972-0.
- Vo Thi Ngoc Chau and Nguyen Hua Phung. Imbalanced educational data classification: An effective approach with resampling and random forest. pages 135–140, 2013.
- Ryan Shaun Joazeiro de Baker, Tiffany Barnes, and Joseph E Beck. Educational data mining 2008. In *The 1st International Conference on Educational Data Mining Montréal, Québec, Canada*, 2008.
- Xiaowen Ding, Xiao Chong, Zhengfeng Bao, Ying Xue, and Shanghong Zhang. Fuzzy comprehensive assessment method based on the entropy weight method and its application in the water environmental safety evaluation of the heshangshan drinking water source area, three gorges reservoir area, china. *Water*, 9:329, 05 2017. doi: 10.3390/w9050329.
- Fundação Francisco Manuel dos Santos. Pordata, estatísticas sobre portugal e a europa. <://www.pordata.pt/Portugal/Estabelecimentos+nos+ensinos+pr2021>. accessed: 12.07.2023.

- Ossama Embarak. Towards an adaptive education through a machine learning recommendation system. pages 187–192, 2021. doi: 10.1109/ICAIC51459.2021.9415211.
- Alfred Essa and Hanan Ayad. Improving student success using predictive models and data visualisations. *Research in Learning Technology*, 2012. doi: 10.3402/rlt.v20i0.19191.
- Hugo Faria. Edubot: A proof-of-concept for a high school motivational agent, 2022.
- Wawan Firgiawan, Nuralamsah Zulkarnaim, and Sugiarto Cokrowibowo. A comparative study using saw, topsis, saw-ahp, and topsis-ahp for tuition fee (ukt). *IOP Conference Series: Materials Science and Engineering*, 875:012088, 07 2020. doi: 10.1088/1757-899X/875/1/012088.
- Anna Galik, Monika Bak, Katarzyna Baładynowicz-Panfil, and Giuseppe Cirella. Evaluating labour market flexibility using the topsis method: Sustainable industrial relations. *Sustainability*, 14:e526, 01 2022. doi: 10.3390/su14010526.
- Filippos Giannakas, Christos Troussas, Akrivi Krouska, C. Sgouropoulou, and Ioannis Voyiatzis. *XGBoost and Deep Neural Network Comparison: The Case of Teams' Performance*, pages 343–349. 07 2021. ISBN 978-3-030-80420-6. doi: 10.1007/978-3-030-80421-3_37.
- Osama Fathy Hegazy Heba. M. Rashad, Walid Mohamed Aly. An educational data mining system for advising higher education students, 2013.
- Ching-Lai Hwang and Kwangsun Yoon. *Methods for Multiple Attribute Decision Making*, pages 58–191. Springer Berlin Heidelberg, Berlin, Heidelberg, 1981. ISBN 978-3-642-48318-9. doi: 10.1007/978-3-642-48318-9_3. URL https://doi.org/10.1007/978-3-642-48318-9_3.
- IEEE. Privacy-preserving patient-centric clinical decision support system on naïve bayesian classification. *IEEE Journal of Biomedical and Health Informatics*, 20:655 – 668, 02 2015.
- Bichkar R. S. Kabra, R. R. Performance prediction of engineering students using decision trees. *International Journal of computer applications*, 36(11), 8-12., 2011.
- Joseph Klein and Herman Ronen. The contribution of a decision support system to educational decision-making processes. *Journal of Educational Computing Research*, 2003. doi: 10.2190/3U4E-XQRO-MK52-AGAM.
- S. B. Kotsiantis. Use of machine learning techniques for educational proposes: A decision support system for forecasting students' grades. *Artificial Intelligence Review*, 2012. ISSN 02692821.

- Lidija Kraujalienė. Comparative analysis of multicriteria decision-making methods evaluating the efficiency of technology transfer. *Business, Management and Education*, 17:72–93, 08 2019. doi: 10.3846/bme.2019.11014.
- Raman Kumar, Sehijpal Singh, Paramjit Singh Bilga, Jatin, Jasveer Singh, Sunpreet Singh, Maria-Luminița Scutaru, and Cătălin Iulian Pruncu. Revealing the benefits of entropy weights method for multi-objective optimization in machining operations: A critical review. *Journal of Materials Research and Technology*, 10:1471–1492, 2021. ISSN 2238-7854. doi: <https://doi.org/10.1016/j.jmrt.2020.12.114>. URL <https://www.sciencedirect.com/science/article/pii/S2238785420321918>.
- Damjan Kužnar and Matjaž Gams. Metis: system for early detection and prevention of student failure, 2016.
- Beatriz Lacerda, Francisco Supino Marcondes, Henrique Lima, Dalila Durães, and Paulo Novais. Prediction of students' grades based on non-academic data. In Marcelo Milrad, Nuno Otero, María Cruz Sánchez Gómez, Juan José Mena Marcos, Dalila Durães, Filippo Sciarrone, Claudio Alvarez-Gómez, Manuel Rodrigues, Pierpaolo Vittorini, Rosella Gennari, Tania Di Mascio, Marco Temperini, and Fernando de la Prieta, editors, *Methodologies and Intelligent Systems for Technology Enhanced Learning, 13th International Conference, MIS4TEL 2023, Guimaraes, Portugal, 12-14 July 2023*, volume 764 of *Lecture Notes in Networks and Systems*, pages 87–95. Springer, 2023. doi: 10.1007/978-3-031-41226-4_9. URL https://doi.org/10.1007/978-3-031-41226-4_9.
- Xiangxin Li, Kongsan Wang, Liwen Liu, Jing Xin, Hongrui Yang, and Chengyao Gao. Application of the entropy weight and topsis method in safety evaluation of coal mines. *Procedia Engineering*, 26:2085–2091, 2011. ISSN 1877-7058. doi: <https://doi.org/10.1016/j.proeng.2011.11.2410>. URL <https://www.sciencedirect.com/science/article/pii/S1877705811052532>. ISMSSE2011.
- Vicente Liern and Blanca Gladish. Multiple criteria ranking method based on functional proximity index: un-weighted topsis. *Annals of Operations Research*, 311, 04 2022. doi: 10.1007/s10479-020-03718-1.
- I. E. Livieris, T. Kotsilieris, V. Tampakas, and P. Pintelas. Improving the evaluation process of students' performance utilizing a decision support software. *Neural Computing and Applications*, 2019.
- Ioannis E Livieris, Tassos A Mikropoulos, and Panagiotis Pintelas. A decision support system for predicting students' performance, 2016.

- Fábio Lobato. Proteção intelectual de obras produzidas por sistemas baseados em inteligência artificial: uma visão tecnicista sobre o tema, 2022.
- Murni Marbun, Muhammad Zarlis, and Zulkifli Nasution. Analysis of application of the saw, wp and tophis methods in decision support system determining scholarship recipients at university. volume 1830, 2021. doi: 10.1088/1742-6596/1830/1/012018.
- Amitha Mathew, P Amudha, and S Sivakumari. Deep learning techniques: an overview. *Advanced Machine Learning Technologies and Applications: Proceedings of AMLTA 2020*, pages 599–608, 2021.
- Ali Mohsin. Systematic review of an automated multiclass detection and classification system for acute leukaemia in terms of evaluation and benchmarking, open challenges, issues and methodological aspects. *Journal of Medical Systems*, 42:204, 11 2018.
- Pedro Jorge Gomes Mota. Comparative analysis of multicriteria decision making methods. 09 2013.
- Romero C Noaman A Mousa Fardoun H Ventura S Márquez-Vera C, Cano A. Early dropout prediction using data mining: A case study with high school students. *Expert Systems*, 2016. ISSN 14680394.
- D.L. Olson. Comparison of weights in tophis models. *Mathematical and Computer Modelling*, 40(7): 721–727, 2004. ISSN 0895-7177. doi: <https://doi.org/10.1016/j.mcm.2004.10.003>. URL <https://www.sciencedirect.com/science/article/pii/S089571770400264X>.
- ONU. Declaração universal dos direitos humanos - artigo 26°. [://www.oas.org/dil/port/19481948](http://www.oas.org/dil/port/19481948). accessed: 12.07.2023.
- Sokkhey Phauk and Takeo Okazaki. Hybrid machine learning algorithms for predicting academic performance. *International Journal of Advanced Computer Science and Applications*, 11, 01 2020a. doi: 10.14569/IJACSA.2020.0110104.
- Sokkhey Phauk and Takeo Okazaki. Developing web-based support systems for predicting poor-performing students using educational data mining techniques. *International Journal of Advanced Computer Science and Applications*, 11:23–32, 2020b. doi: 10.14569/IJACSA.2020.0110704.
- Sanjay P Prabhu. Ethical challenges of machine learning and deep learning algorithms. *The Lancet Oncology*, 20(5):621–622, 2019.
- Cláudia Prioste. Teachers' hypotheses on academic failure in the early grades of elementary school, 2020.

- Saima Rafi, Wu Yu, Muhammad Azeem Akbar, Ahmed Alsanad, and Abdu Gumaiei. Prioritization based taxonomy of devops security challenges using promethee. *IEEE Access*, pages 105426–105446, 2020. doi: 10.1109/ACCESS.2020.2998819.
- Rianto, Djoko Budiyanto, Setyohadi, and Suyoto. Ahp-topsis on selection of new university students and the prediction of future employment. In *2017 1st International Conference on Informatics and Computational Sciences (ICICoS)*, pages 125–130, 2017. doi: 10.1109/ICICoS.2017.8276349.
- Ewa Roszkowska. Multi-criteria decision making models by applying the topsis method to crisp and interval data. 2011.
- Sunita S Padmannavar Safira Begum. Prediction of student performance using genetically optimized feature selection with multiclass classification. © 2022 by *IJETT Journal*, 70(24), 2022. doi: 10.14445/22315381/IJETT-V70I4P219.
- Ria Eka Sari, Abdul Meizar, Dahriani Hakim Tanjung, and Ahir Yugo Nugroho. Decision making with ahp for selection of employee, 2017.
- Research Scholar, Harish Nagar Associate Professor, and Sarvottam Dixit. Decision support system model for student performance detection using machine learning. *International Journal of Engineering Research Technology (IJERT) www.ijert.org*, 2021. ISSN 2278-0181.
- Agus Setyawan, Florentina Arini, and Isa Akhlis. Comparative analysis of simple additive weighting method and weighted product method to new employee recruitment decision support system (dss) at pt. warta media nusantara. *Scientific Journal of Informatics*, 4, 2017. doi: 10.15294/sji.v4i1.8458.
- J.P. Shim, Merrill Warkentin, James F. Courtney, Daniel J. Power, Ramesh Sharda, and Christer Carlsson. Past, present, and future of decision support technology. *Decision Support Systems*, 33(2):111–126, 2002. ISSN 0167-9236. doi: [https://doi.org/10.1016/S0167-9236\(01\)00139-7](https://doi.org/10.1016/S0167-9236(01)00139-7). URL <https://www.sciencedirect.com/science/article/pii/S0167923601001397>.
- Ansar Siddique, Asiya Jan, Fiaz Majeed, Adel Ibrahim Qahmash, Noorulhasan Naveed Quadri, and Mohammad Osman Abdul Wahab. Predicting academic performance using an efficient model based on fusion of classifiers. *Applied Sciences*, 11(24):11845, Dec 2021. ISSN 2076-3417. doi: 10.3390/app112411845.
- Yogesh Singh, Pradeep Kumar Bhatia, and Omprakash Sangwan. A review of studies on machine learning techniques. *International Journal of Computer Science and Security*, 1(1):70–84, 2007.

- Hamed Taherdoost and Mitra Madanchian. Multi-criteria decision making (mcdm) methods and concepts. *Encyclopedia*, 3(1):77–87, 2023. ISSN 2673-8392. doi: 10.3390/encyclopedia3010006. URL <https://www.mdpi.com/2673-8392/3/1/6>.
- Thilagaraj Thangamuthu and Sengottaiyan Nallasamy. A review of educational data mining in higher education system. pages 349–358, 06 2017. doi: 10.15439/2017R87.
- Evangelos Triantaphyllou, B. Shu, S. Sanchez, and Thomas Ray. *Multi-criteria decision making: An operations research approach*, volume 15, pages 175–186. 02 1998.
- Demetrios Tsesmelis, Panagiotis Oikonomou, Constantina Vasilakou, Nikolaos Skondras, Vassilia Fassouli, Stavros Alexandris, Neil Grigg, and Christos Karavitis. Assessing structural uncertainty caused by different weighting methods on the standardized drought vulnerability index (sdvi). *Stochastic Environmental Research and Risk Assessment*, 33, 02 2019. doi: 10.1007/s00477-019-01648-4.
- Conselho UE. Resolução do conselho sobre um quadro estratégico para a cooperação europeia no domínio da educação e da formação rumo ao espaço europeu da educação e mais além (2021-2030), 2021.
- Indira Uvalieva and Saule Smailova. Development of decision support system to control the quality of education. 2014. ISBN 9781479941209.
- Bruno Veloso. A systematic review on student failure prediction, 2022.
- Masna Wati, Niken Novirasari, Edy Budiman, and Haeruddin. Multi-criteria decision-making for evaluation of student academic performance based on objective weights, 2018.
- Wira Trise Putra, Dede and Agustian Punggara, Adrian. Comparison analysis of simple additive weighting (saw) and weighed product (wp) in decision support systems. *MATEC Web Conf.*, 215:01003, 2018. doi: 10.1051/mateconf/201821501003. URL <https://doi.org/10.1051/mateconf/201821501003>.

Coloque aqui informação sobre financiamento, projeto FCT, etc. em que o trabalho se enquadra. Deixe em branco caso contrário.