

# Formação de equipes heterogêneas: suporte ao docente para aplicação da Aprendizagem Baseada em Equipes

Johnny Y. Solano Marinho, Damires Y. Souza Fernandes

Programa de Pós-Graduação em Tecnologia da informação – Instituto Federal da Paraíba (IFPB) João Pessoa – PB – Brasil

johnnyyuri88@gmail.com, damires@ifpb.edu.br

**Abstract.** *A classroom naturally offers different profiles in terms of levels of learning, interaction or engagement. This work presents an approach that identifies student profiles in a class and, based on them, forms heterogeneous groups to help applying Active Learning Practices (ALP). To do so, it uses an unsupervised machine learning method to create homogeneous groups and defines an adapted strategy for forming groups with heterogeneous and specific profiles for ALPs. The approach was evaluated based on real data from integrated technical high school classes considering the ALP called Team-Based Learning (TBL).*

**Resumo.** *Turmas de estudantes naturalmente apresentam perfis diferentes em relação a níveis de aprendizagem, interação ou engajamento. Este trabalho apresenta uma abordagem que identifica perfis de estudantes em uma turma e, com base neles, forma grupos heterogêneos com vistas à aplicação de Práticas Ativas de Aprendizagem (PAA). Para tal, usa um método de aprendizado de máquina não supervisionado para criação de grupos homogêneos e define uma estratégia adaptada para a formação de grupos com perfis heterogêneos específicos para PAAs. A abordagem foi avaliada com base em dados reais de turmas do ensino técnico integrado ao médio considerando a PAA denominada Aprendizagem Baseada em Equipes (ABE).*

## 1. Introdução

Conforme Freire (1997), Blikstein (2012) e Pachane et al. (2004), o cenário educacional brasileiro é caracterizado, em algumas situações, pela utilização de práticas tradicionais, algumas vezes denominadas de pedagogia bancária. O termo “pedagogia bancária” remete à prática docente centrada no conteúdo, quando ocorre a transmissão uniforme e depósito de informações e conhecimento no estudante [Freire,1981]. Nesse panorama, o professor é peça-chave para a modificação e melhoria do cenário educacional. Contudo, muitos não possuem formação pedagógica ou ainda desconhecem estratégias além das práticas tradicionais comumente utilizadas [Moran, 2007; Moran, 2015].

Um dos desafios do professor diz respeito a lidar com a heterogeneidade dos estudantes em uma turma, cenário que requer do professor uma inventividade didática [Perrenoud,2015]. Neste aspecto, as metodologias ativas tais como, Sala de Aula Invertida [Bacich et al., 2018], Aprendizagem baseada em Equipes (ABE) [Bollela,2014] e Trezentos [Fragelli, 2019], entre outras, aparecem como propostas

diferenciadas para dinamizar o ambiente escolar e auxiliar o docente na condução do ensino em turmas heterogêneas. As metodologias ativas podem ser definidas como “Estratégias de ensino centradas na participação efetiva dos estudantes na construção do processo de aprendizagem, de forma flexível, interligada e híbrida” [Bacich et al. 2018].

Neste trabalho, utiliza-se o termo Práticas Ativas de Aprendizagem (PAA) na referência a métodos, abordagens, estratégias de ensino centrados no estudante com o intuito de auxiliar na condução da prática docente diante de um cenário heterogêneo de uma turma. Frente ao panorama apresentado, originam-se as questões de pesquisa que norteiam este trabalho: Q1: Diante dos diferentes perfis dos estudantes em uma turma, como formar ou agrupar perfis similares de estudantes? E Q2: A partir dos grupos de estudantes com perfis similares identificados, como formar outros grupos com perfis heterogêneos e associar esses grupos a determinadas PAAs? Para responder as questões formuladas, este estudo apresenta a abordagem ActivePlan que provê um processo e ferramenta para suporte ao docente mediante a identificação de grupos de estudantes com perfis heterogêneos com vista a utilização de algumas PAAs. Neste trabalho, o foco é instanciar a abordagem para a formação de equipes para a prática ABE. São utilizados dados obtidos da educação profissional técnica e, com base neles, é realizada uma avaliação experimental com o objetivo de medir o grau de diversidade dos grupos obtidos frente à prática ABE. O artigo está organizado da seguinte forma: a Seção 2 aborda conceitos e alguns trabalhos relacionados a esta temática; A Seção 3 apresenta a abordagem ActivePlan; a Seção 4 descreve e discute a avaliação experimental realizada; A Seção 5 discorre sobre conclusões e trabalhos futuros.

## 2. Referencial teórico e Trabalhos relacionados

Esta seção introduz conceitos e aborda alguns trabalhos relacionados a este estudo.

### 2.1. Aprendizagem Baseada em Equipes

A ABE é uma PAA que normalmente é organizada em etapas conforme apresentado na Figura 1 [Alcantara et al. 2020]. Neste processo, na Etapa 1, divide-se a turma em equipes heterogêneas. As Etapas 2 e 3 tem foco na preparação individual do estudante, que estuda algum material disponibilizado pelo docente (Etapa 2) e realiza um teste individualmente (Etapa 3). Na Etapa 4 acontece um teste coletivo, com todos membros do grupo. A Etapa 5 destina-se aos apelos ou recursos que podem ocorrer diante da divergência em relação a gabarito(resposta correta). Na etapa 6 o professor pode realizar uma intervenção com objetivo de esclarecer e fornecer um *feedback* e auxílio nas principais dificuldades e duvidas referentes ao tema abordado.

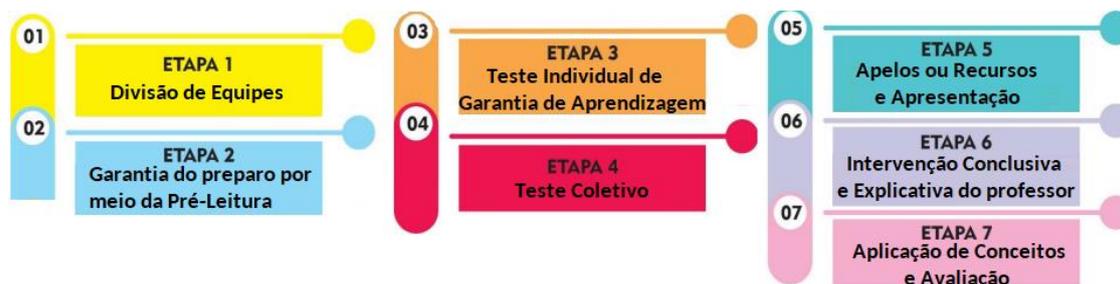


Figura 1 - Etapas da ABE [Adaptado de Alcantara et al. 2020].

A Etapa 7 destina-se à aplicação dos conceitos mediante um processo de avaliação, os estudantes são desafiados a fazerem interpretação, inferências, análises ou síntese. Para Bolleta et al. (2014), um dos quatro princípios essenciais para aplicação da ABE refere-se a formação das equipes, ou seja, para que as equipes alcancem alto desempenho, sejam coesas e eficientes, a utilização da ABE requer que à formação de grupos considere entre cinco a sete membros de perfis distintos.

## 2.2. Mineração de Dados Educacionais e o método K-means

A Mineração de Dados Educacionais (MDE) é considerada uma subárea da Mineração de Dados [Romero et al., 2013]. A MDE utiliza algoritmos de aprendizado de máquina para descobrir padrões e análises a partir de dados que normalmente são gerados e explorados em Ambientes Virtuais de Aprendizagem (AVA) [Silva et al., 2021], a exemplo do MOODLE (Modular Object-Oriented Dynamic Learning Environment) e do Google Classroom [Souza et al., 2020]. Tais dados disponíveis podem originar-se de interações dos estudantes, professores e tutores, logs de acesso, ou mesmo de atividades de ensino por meio dos AVAs [Dalcin et al., 2021]. Estudos de aplicação de MDE estão normalmente focados em assistir docentes e gestores educacionais na mitigação de questões como retenção de alunos, problemas de desempenho escolar, detecção de comportamentos, evasão discente, entre outros. O Aprendizado de Máquina (AM) forma a base técnica necessária à MDE. Dois dos principais paradigmas do AM são o supervisionado e o não supervisionado [Harrington, 2012]. No primeiro, o aprendizado ocorre a partir de exemplos rotulados. Já no segundo, o aprendizado é baseado apenas nos objetos do conjunto de dados cujos rótulos são desconhecidos. Neste trabalho, o método K-Means, um exemplo de algoritmo não supervisionado, é utilizado. O K-Means permite a criação de grupos (clusters) que agrupam objetos por similaridade.

## 2.3. Avaliação de grupos

No tocante à avaliação de grupos gerados por meio de métodos como o K-Means, uma das medidas mais utilizadas refere-se ao coeficiente de silhueta (do francês, *silhouette*) [Rousseeuw, 1987]. Esse coeficiente indica o quão bem uma instância está alocada a um dado cluster. Ele pode refletir valores dentro do intervalo de [-1; +1]. Um valor alto (mais próximo de 1) indica uma configuração de cluster mais apropriada, e valores próximos a zero revelam a alocação inconclusiva (instância poderia estar tanto no seu cluster quanto em algum outro cluster) e, perto de -1, o valor indica que a alocação foi realizada de forma não adequada.

Particularmente, para avaliar o grau de heterogeneidade de grupos, é preciso mensurar a “diversidade” entre as instâncias em cada grupo de modo que esta seja a maior possível. Assim a métrica *diversidade* de cada grupo pode ser calculada mediante a Fórmula (1) [Kuo et al., 1993].

$$\sum_{i=1}^{n-1} \sum_{j=i+1}^n d_{ij} \quad (1)$$

Onde,  $d$  representa a distância euclidiana entre os elementos do grupo, e  $i$  e  $j$  indicam os índices dos elementos de cada instância. Por meio dessa métrica, pode-se verificar se a diversidade entre as instâncias dos grupos formados foi maximizada.

## 2.4. Trabalhos Relacionados

Alguns trabalhos associados a este estudo são brevemente descritos nesta seção.

No trabalho de Pimentel et al. (2003), dados foram coletados a partir de questionários em turmas de graduação de cursos de informática de duas instituições de ensino superior. O trabalho apontou que é possível formar grupos consistentes que se aproximaram do esperado pelo docente no estudo de caso. Algumas das sugestões de trabalhos futuros do estudo de Pimentel et al. (2003) indicam a possibilidade de formação de grupos homogêneos e heterogêneos, através do uso de pedagogias diferenciadas. No tocante à criação de grupos heterogêneos, eles sugerem que essa tarefa possa ser realizada a partir dos membros dos grupos homogêneos.

Ramos et al. (2020) utilizaram agrupamento objetivando a identificação de perfis de estudantes de graduação. Para isso, coletaram dados oriundos das interações em AVA referente aos cursos de Administração Pública e Pedagogia. Depois da etapa de coleta e seleção, realizou-se o pré-processamento e o tratamento dos dados para aplicação de algoritmos de clusterização, dentre eles o K-Means. Foi definida a necessidade de 3 clusters para identificação de perfis de interação dos grupos de estudantes categorizados em baixa, média e alta interação. Os resultados obtidos apontaram que foi possível a identificação dos diferentes perfis de estudantes quanto à interação.

O estudo de Monteverde et al., (2018) realizou a formação de grupos de estudantes com perfis homogêneos para atividades de aprendizagem colaborativa de duas turmas de curso a distância que utilizavam-se do AVA MOODLE. No tocante ao processo de formação dos grupos, utilizou-se a ferramenta M-Cluster proposta por Monteverde et al., (2017) em trabalho anterior. Mediante o M-Cluster, agrupam-se os estudantes de acordo com o grau de similaridade em termos de interação do estudante no AVA utilizado. O professor ou tutor seleciona, manualmente, a distância a ser aplicada ao algoritmo K-Means, assim como a definição da quantidade de grupos para formação. O tutor ou professor é responsável por analisar os clusters e grupos de estudantes gerados.

Nalli et al., (2021) visaram à formação de grupos heterogêneos. Para isso, o trabalho primeiramente, realiza o agrupamento dos estudantes em clusters, considerando a similaridade do comportamento de cada estudante (instância) na interação com o AVA. O índice de silhueta foi utilizado na avaliação dos resultados do agrupamento. No trabalho, são obtidos 3 grupos (Cluster 0, Cluster 1 e Cluster 2), onde os clusters representam o grau de atividade dos estudantes, ou seja, do mais intenso (Cluster 2) ao menos ativo (Cluster 0). A partir dos clusters obtidos, os estudantes são distribuídos em grupos de estudantes com perfis heterogêneos para utilização do professor. O trabalho implementou também um plugin para o MOODLE com a estratégia proposta.

Maina et al., (2017) também realizaram um estudo visando a geração de grupos compostos por estudantes com perfis heterogêneos. A abordagem apresentada foi dividida em duas etapas: (i) Criação de clusters, com grupos homogêneos, e (ii) Implementação de agrupamento inteligente, com a formação de grupos heterogêneos. A primeira etapa utiliza dados provenientes de fóruns de estudantes, incluindo: número de posts; número de respostas (*replies*); e a classificação média das postagens (*forum ratings*). Mediante o método de agrupamento, obtém-se 3 grupos (Cluster 0, Cluster 1 e

Cluster 2). Cada cluster está associado a um nível de competência de colaboração, denominados de, respectivamente, “alto”, “médio” ou “baixo”. O algoritmo proposto por Maina et al., (2017) pode ser resumido da seguinte forma: (i) As instâncias presentes em cada cluster (Cluster 0, Cluster 1 e Cluster 2) são embaralhadas; (ii) Depois, os estudantes são ordenados de forma decrescente por meio dos clusters; (iii) A partir da ordenação, alocam-se os estudantes, de diferentes níveis de colaboração, a novos grupos. O processo é realizado iterativamente até que todos os alunos sejam atribuídos a um grupo. Os estudantes considerados mais interativos recebem a função de mentor em seu grupo.

Observa-se que, de modo geral, os trabalhos relacionados utilizam o algoritmo K-Means para agrupamento dos estudantes com perfis homogêneos. Boa parte deles utilizam AVA MOODLE como fonte de dados que são obtidos a partir de valores históricos.

Comparando os trabalhos com este, alguns diferenciais são apontados: (i) a abordagem considera dados de estudantes em turmas remotas por meio do AVA, denominado Google Sala de aula (Classroom) e de sistemas administrativos educacionais como o Sistema de Processo Administrativo Eletrônico (SPAEE) denominado SUAP (Sistema Unificado da Administração Pública); (ii) a abordagem realiza, após a etapa de pré-processamento dos dados, uma atividade de enriquecimento dos dados. Neste trabalho, o enriquecimento é realizado por meio da análise cognitiva dos alunos utilizando o Coeficiente de Rendimento do Estudante (CRE); (iii) Outro diferencial do presente trabalho refere-se à busca pela formação de grupos mistos de estudantes direcionados para ABE.

### 3. Abordagem ActivePlan

A Figura 2 apresenta a Etapa I e a Etapa II com as ações que envolvem ambas as etapas da abordagem desenvolvida. A **Etapa I** é composta pela coleta de dados e seu enriquecimento. O enriquecimento dos dados ocorre por meio da adição de novos indicadores a respeito dos discentes. Inicialmente, foi definido o uso da Taxonomia de Bloom para avaliar o grau de desempenho [Marinho & Souza 2022]. Neste trabalho, o enriquecimento é realizado utilizando-se do CRE.

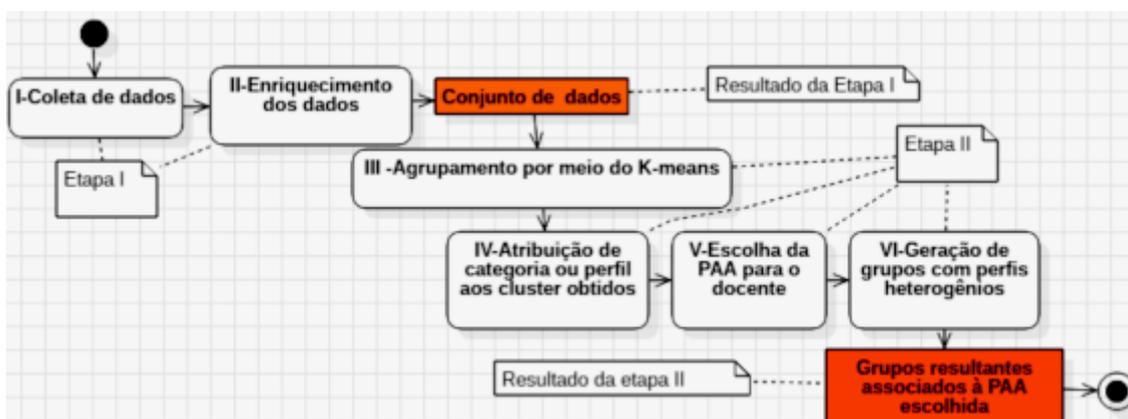


Figura 2. Atividades na Abordagem ActivePlan

A **Etapa II** engloba a criação de grupos tanto homogêneos quanto heterogêneos para PAAs. Os clusters obtidos por meio do K-Means são formados por estudantes que foram associados considerando a similaridade de seus perfis. Nesse contexto, cada estudante é associado a uma classe ou categoria (perfil) conforme o cluster que o contém. Cada cluster recebe uma atribuição conforme suas características a exemplo de estudos de categorizações realizadas em [Oliveira et al. 2022; Nalli et al, 2021; Pereira et al., 2021; Ramos et al.,2020; Moubayed et al. ,2020; Macedo et al. ,2020; Pereira et al. 2018]. Considerando a PAA ABE, tem-se os clusters, após a categorização dos clusters e sua atribuição a cada instância de estudante, a abordagem prossegue para a geração de grupos heterogêneos. Isso é realizado por meio dos seguintes passos:

1. Para cada cluster, **extrai-se a identificação dos estudantes (IDs)** juntamente com os valores correspondentes aos atributos elencados;
2. **Extraem-se as médias de cada cluster** referentes aos atributos elencados, considerando todos elementos dos clusters;
3. **Calcula-se uma pontuação** para cada cluster a partir das médias dos atributos extraídas conforme Passo 2;
4. **Categorizam-se os clusters considerando a pontuação obtida**, retornando as identificações de estudantes (IDs) devidamente ordenadas conforme o desempenho. As categorias foram definidas: Desempenho Muito Elevado (DME), Desempenho Elevado (DE), Desempenho Moderado (DM), Desempenho Baixo (DB), Desempenho Muito Baixo (DMB).
5. **A lista é ordenada conforme categorização atribuída**, composta de IDs de estudantes;
6. **A lista é submetida ao algoritmo adaptado para geração de equipes heterogêneas**. Baseando-se no algoritmo proposto por Maina et. al (2017) que visa atribuir um estudante a um determinado grupo, ao final do processo este algoritmo gera grupos heterogêneos para aplicação em PAA.

#### 4.0. Experimentos e Resultados

Os resultados obtidos neste trabalho incluem uma ferramenta para suporte docente e avaliações experimentais realizadas para responder às questões de pesquisa, focadas na aplicação da PAA ABE. A ferramenta foi implementada como uma aplicação WEB, desenvolvida a partir da linguagem python, mediante framework Django [Django 2020].

##### 4.1. Ferramenta Activeplan

A interface principal da ferramenta é mostrada na Figura 3a. Ela indica a possibilidade de seleção de perfil de usuário professor (I). Apresentam-se na Figura 3b detalhes da configuração a ser feita pelo professor, o que inclui a informação da escolha de qual PAA deve ser considerada (II) e, a PAA ABE necessita da inserção da quantidade de membros por grupo (III) conforme descrito na Seção 2.1. Caso o professor já tenha definido a quantidade de membros por grupo, este pode inseri-las diretamente (IV). Por fim, o professor deve indicar o conjunto de dados a ser utilizado (V).



Figura 3a e 3b: a) Tela principal da interface da ActivePlan; b) Opções para o módulo do professor.

## 4.2. Conjuntos de dados

O estudo de Souza et al. (2020) coletou e integrou dados a partir das seguintes fontes: SUAP (492 instâncias de estudantes) e Google classroom (488 instâncias de estudantes). Assim, os dados oriundos do SPAE e do AVA resultaram em um dataset que contém dados pertencentes a turmas do ensino médio integrado de curso técnico referentes aos cursos: Técnico de Edificações, Manutenção e Suporte em Informática e Edificação de turmas referentes ao primeiro, segundo e terceiro ano.

As experimentações da Seção 4.3 referem-se às turmas pertencentes ao segundo e terceiro ano dizem respeito apenas à disciplina de filosofia, inclui um conjunto que inclui 128 estudantes do segundo ano e 101 estudantes do terceiro ano, totalizando o montante de 229 instâncias de estudantes das 492 coletadas por Souza et al. (2020).

Tabela 1: Metadados estruturais do dataset original juntamente com dados enriquecidos das turmas do segundo e terceiro ano

Atributos	Descrição	Fonte	Intervalo de valores
Q1 -	Nota da primeira atividade	AVA	[00;99]
Q2 -	Nota da segunda atividade	AVA	[00;99]
T1 -	Tempo de envio da primeira avaliação (em dias)	AVA	[00;99]
T2 -	Tempo de envio da segunda avaliação (em dias)	AVA	[00;99]
S1-	Último acesso da primeira avaliação (tempo em dias)	SPAE	[00;99]
S2-	Último acesso da segunda avaliação (tempo em dias)	SPAE	[00;99]
CRE -	Média dos históricos das notas em disciplinas	SPAE	[00;99]

Os atributo em destaque na cor cinza é oriundo do processo de enriquecimento do conjunto de dados disponibilizado por Souza (2020). O CRE corresponde à média das notas obtidas pelo estudante nas disciplinas do ano anterior, tais como: Biologia, Física, Filosofia, Português, Geografia, Matemática, Educação Física, Química, História, Sociologia.

## 4.3 Avaliação Experimental

Dois experimentos foram planejados com os seguintes objetivos:

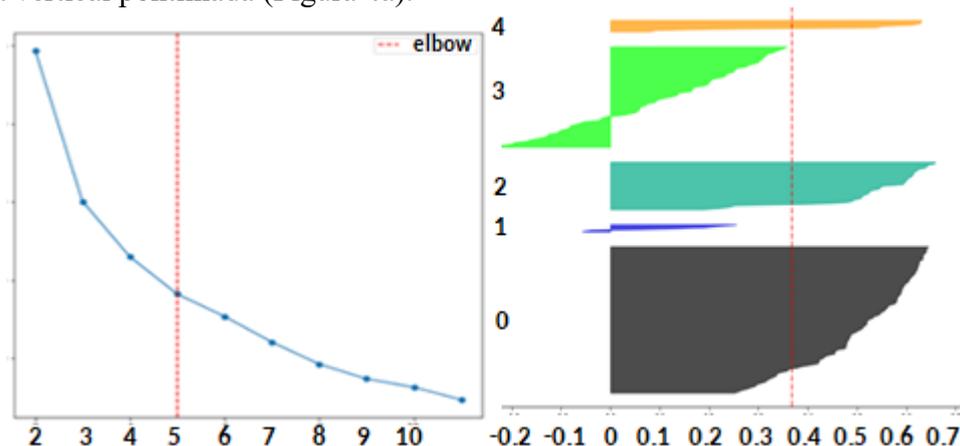
**Experimento I:** busca verificar o nível de similaridade de perfis de estudantes agrupados em clusters (respondendo à primeira questão de pesquisa);

**Experimento II:** objetiva analisar a diversidade obtida nos grupos formados com perfis distintos de estudantes com respeito à PAA ABE (respondendo à segunda questão de pesquisa).

Os experimentos foram realizados em máquina local. As configurações de *hardware* incluem: Processador Intel, 8ª geração, core i5-8250U, 8GB de memória RAM, 1 Terabyte de armazenamento. Para a realização de atividades de modelagem do aprendizado (por meio de algoritmo de clusterização) e avaliação mediante métrica *silhouette*, utilizou-se a biblioteca *scikitlearn*<sup>1</sup>. Para a implementação de cálculos matemáticos (e.g., cálculo de distância entre instâncias) utilizou-se a biblioteca *scipy*<sup>2</sup>. Na exibição de alguns resultados, utilizou-se as bibliotecas *matplotlib*<sup>3</sup> e *seaborn*<sup>4</sup>. Para auxílio no tratamento, enriquecimento e manipulação dos dados, utilizou-se as bibliotecas *numpy*<sup>5</sup> e *pandas*<sup>6</sup>.

#### 4.3.1 Experimento I: Identificação de perfis de estudantes para a ABE

O método Elbow indicou um quantitativo de cinco clusters a ser utilizado, como mostra a linha vertical pontilhada (Figura 4a).



**Figura 4a e 4b: a) Elbow e a quantidade de clusters b) Índice de silhueta do conjunto de dados do segundo e terceiro ano**

Usando, então, a configuração de cinco clusters, o K-means foi executado e obteve-se os resultados mostrados conforme apresentado na Figura 4a. A qualidade da atribuição das instâncias a um determinado cluster foi mensurada mediante o índice de silhueta. A média da Silhueta (Figura 4b) aponta para o valor 0.37, próximo a 0.4, o que pode indicar que o agrupamento por similaridade, foi realizado de forma satisfatória para alguns clusters e insatisfatória ou inconclusiva na alocação de instâncias de outros

<sup>1</sup>Disponível em: <https://scikit-learn.org/>. Acesso em: 20 maio de 2022

<sup>2</sup>Disponível em: <http://scipy.org/>. Acesso em: 27 maio de 2022

<sup>3</sup>Disponível em: <https://matplotlib.org/>. Acesso em: 20 maio de 2022

<sup>4</sup>Disponível em: <https://seaborn.pydata.org/>. Acesso em: 20 maio de 2022

<sup>5</sup>Disponível em: <https://numpy.org/>. Acesso em: 20 maio de 2022

<sup>6</sup>Disponível em: <https://pandas.pydata.org/>. Acesso em: 20 maio de 2022

clusters. Dessa forma, os Clusters 4, 2 e 0 obtiveram um índice de silhueta próximo a 0.6. Assim, verifica-se, para estes clusters, uma consistência na seleção de estudantes no que tange à similaridade intra-cluster (quanto mais próximo a um, mais coesa foi a alocação da instância ao cluster). Em sua maioria, a média do *Silhouette* apresenta valores acima do limiar padrão de 0.5. Percebe-se que parcela dos índices de silhueta apresentam valores negativos associados aos Clusters 3 e 1, o que indica que alguns estudantes pertencentes a esses clusters possivelmente foram erroneamente alocados.

### 4.3.2. Experimento II: Formação de grupos heterogêneos para a ABE

A Tabela 2 propicia uma visão do panorama dos perfis dos estudantes conforme os grupos obtidos e indica uma pontuação para cada atributo vs cluster.

**Tabela 2: Ranking dos clusters a partir das médias de cada atributo**

Atributos	Cluster (C0)		Cluster 2 (C2)		Cluster 4 (C4)		Cluster 3 (C3)		Cluster 1 (C1)	
	Média	Pontos	Média	Pontos	Média	Pontos	Média	Pontos	Média	Pontos
Q1	0.90	0	0.71	1	0.13	4	0.64	2	0.60	3
Q2	0.90	0	0.79	1	0.08	4	0.77	2	0.25	3
T1	0.02	0	0.05	3	0.86	4	0.04	2	0.04	1
T2	0.03	0	0.06	2	0.78	3	0.04	1	1.0	4
S1	0.03	1	1.0	3	1.0	3	0.03	0	0.52	2
S2	0.03	0	0.08	2	0.89	4	0.07	1	0.18	3
CRE	0.67	0	0.44	1	0.38	3	0.04	2	0.29	4
<i>Total de pontos</i>		1	-	13	-	25	-	10	-	20

Conforme estratégia de pontuação definida Seção 3.0, verifica-se que o C0 obteve menor pontuação e foi eleito o cluster de DME (quanto menor pontuação obtida, melhor é o desempenho do cluster). Já o C4 foi o que agrupou os estudantes com pior desempenho (DMB). As instâncias do C3, C2 e C1 foram categorizadas, respectivamente, a partir do DE, DM e DB. A Figura 5a, é possível verificar a atribuição dos estudantes aos clusters e a atribuição dos níveis de desempenhos aos clusters.

Clusters	Estudantes	Desempenhos	ID	cluster	Grupos
C4	[8, 26, 41, 125, 128, 155, 168, 196, 200]	Desempenho muito baixo	146	C0	G37
			69	C0	G37
			207	C3	G37
			96	C3	G37
			172	C2	G37
C1	[0, 3, 122, 132, 161, 189]	Desempenho baixo	26	C4	G37
			148	C0	G35
			73	C0	G35
			215	C3	G35
C2	[9, 17, 20, 21, 29, 33, 35, 39, 57, 67, 70, 71, 79, 85, 86, 88, 94, 129, 131, 135, 140, 145, 156, 167, 172, 175, 187, 188, 194, 205, 213, 218, 225, 226, 228]	Desempenho moderado	106	C3	G35
			187	C2	G35
			125	C4	G35
			149	C0	G34
C3	[4, 5, 6, 7, 12, 16, 24, 25, 27, 28, 31, 42, 43, 44, 45, 47, 48, 50, 51, 54, 55, 62, 65, 75, 78, 87, 90, 96, 103, 106, 107, 108, 110, 111, 114, 115, 118, 123, 130, 133, 134, 136, 137, 138, 139, 141, 151, 153, 158, 159, 163, 165, 170, 171, 176, 177, 179, 181, 183, 191, 192, 193, 195, 201, 202, 207, 208, 215, 216, 219, 220, 221]	Desempenho elevado	74	C0	G34
			216	C3	G34
			107	C3	G34
			188	C2	G34
C0	[1, 2, 10, 11, 13, 14, 15, 18, 19, 22, 23, 30, 32, 34, 36, 37, 38, 40, 46, 49, 52, 53, 56, 58, 59, 60, 61, 63, 64, 66, 68, 69, 72, 73, 74, 76, 77, 80, 81, 82, 83, 84, 89, 91, 92, 93, 95, 97, 98, 99, 100, 101, 102, 104, 105, 109, 112, 113, 116, 117, 119, 120, 121, 124, 126, 127, 142, 143, 144, 146, 147, 148, 149, 150, 152, 154, 157, 160, 162, 164, 166, 169, 173, 174, 178, 180, 182, 184, 185, 186, 190, 197, 198, 199, 203, 204, 206, 209, 210, 211, 212, 214, 217, 222, 223, 224, 227]	Desempenho muito elevado	128	C4	G34
			147	C0	G36
			72	C0	G36
			208	C3	G36
			103	C3	G36
			175	C2	G36
			41	C4	G36

**Figura 5a e 5b: a) Resultados da identificação de perfis dos clusters; b) Fragmentos de Resultados da geração de grupos heterogêneos.**

Os resultados da identificação e categorização dos perfis dos clusters são apresentados na Figura 5a. A Figura 5b mostra um fragmento do resultado da atribuição

dos estudantes aos grupos heterogêneos, dois grupos são apresentados. No experimento foram atribuídos seis estudantes para formação de cada grupo. Os grupos heterogêneos criados para ABE apresenta 38 grupos, quanto à distribuição de perfis de estudantes vs grupos, percebe-se que: Os Grupos 37 ao 31 são compostos de estudantes com os seguintes perfis: dois estudantes DME, dois DE, um DM e um DB. O Grupo 30 é formado por estudantes com os seguintes perfis: três estudantes DME, um DE, um DM e um DB. Os Grupos 29 ao 27 são formados por estudantes com os seguintes perfis: três estudantes DME, um DE, um DM e um DMB. Os Grupos 26 ao 24 são compostos de estudantes com perfis assim: três estudantes de perfil DME, dois estudantes de DE e um de DMB. Verifica-se, conforme mostra a Figura 6 que predominantemente o grupo 25 até 37 apresenta elevado índice de diversidade (acime da média, linha horizontal pontilhada). Os Grupos 1 e 23 são constituídos de estudantes: três estudantes de perfil DME, dois estudantes de DE e um estudante de DM. O Grupo 0 é formado por estudantes com os seguintes perfis: três estudantes DME, dois DE e um DB.

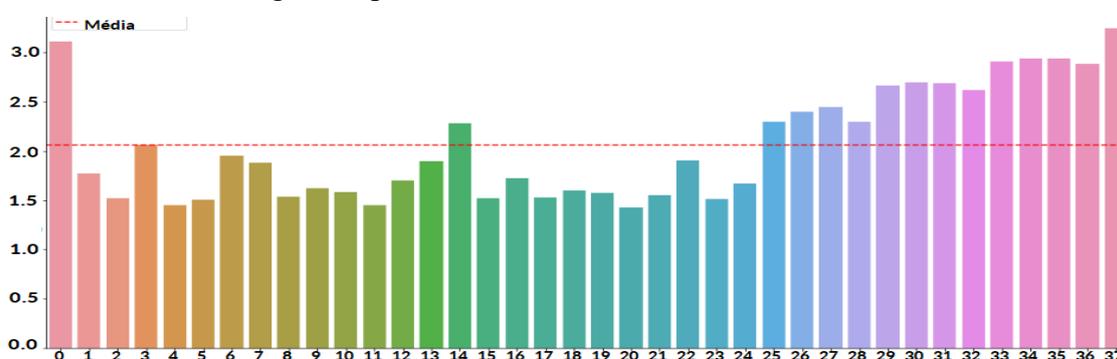


Figura 6 - Índice de diversidade de cada grupo

Os resultados do índice de diversidade apresentados para cada grupo possibilita-se uma visão da heterogeneidade e do balanceamento da composição dos grupos. Dessa forma, pode prover suporte ao docente na formação dos grupos heterogêneos.

## 5.Considerações finais e Trabalhos futuros

Este trabalho apresentou uma abordagem que busca auxiliar o docente na utilização de práticas ativas de aprendizagem para cenários de turmas com perfis heterogêneos de estudantes com foco na PAA ABE. Para isso, a abordagem ActivePlan realiza o enriquecimento de perfis de estudantes com indicadores de seus desempenhos com base no CRE. A abordagem faz uso do método K-Means e propõe uma estratégia para formação de grupos de estudantes com perfis heterogêneos. Mediante a avaliação experimental realizada, considera-se que a formação de grupos heterogêneos para a PAA ABE atingiu resultados promissores. A razão para isso é o grau de heterogeneidade, cuja a média de diversidade dos grupos formados resultaram em valores próximos, pois todos os grupos foram constituídos de perfis distintos.

Como trabalhos futuros, pretende-se explorar outros atributos que envolvam componentes demográficos, referentes aos estudantes e a ausência de recursos, relevantes para o contexto e objetivos elencados pelo docente para aplicação da ABE. Outras avaliações, mediante estudo de caso possibilita avaliar qualitativamente os grupos gerados. Processo de implantação em sistemas de suporte a ABE [Giacomelli, 2020], AVAs ou SPAEs podem ser considerados.

## Referências

- Alcantara, E. F. (2020). Inovação e renovação acadêmica: guia prático de utilização de metodologias e técnicas ativas. Volta Redonda, RJ: FERP. ISBN: 978-85-66196-17-7
- Bacich, L., & Moran, J. (2018). Metodologias ativas para uma educação inovadora: uma abordagem teórico-prática. Penso Editora.
- Blikstein, P. (2012). O mito do mau aluno e porque o Brasil pode ser o líder mundial de uma revolução educacional.
- Bollela, V. R., Senger, M. H., Tourinho, F. S. V., & Amaral, E. (2014). Aprendizagem baseada em equipes: da teoria à prática. *Medicina (Ribeirão Preto)*, 47(3), 293-300.
- Django (2020). Django documentation. Django Software Foundation. Disponível em: <https://www.djangoproject.com>. Acesso em: 11 fev. 2020.
- Dalcin, E., Abegg, I., & Ceretta, P. S. (2021). o uso de tecnologias digitais no processo de ensino e aprendizagem no moodle: um mapeamento sistemático da literatura. *revista tecnologias educacionais em rede (reter)*, 2(3), 8-01.
- Fragelli, R. (2019). Método trezentos: Aprendizagem ativa e colaborativa, para além do conteúdo. Penso Editora.
- Freire, P. (1997). Educação “bancária” e educação libertadora. *Introdução à psicologia escolar*, v. 3, p. 61-78,.
- Giacomelli, S. C. P. (2020). O uso da metodologia TEAM-BASED LEARNING (TBL) aliada à tecnologia: percepções sobre a aprendizagem de contabilidade básica no Curso Técnico em Administração.
- Harrington, P. (2012). *Machine learning in action*. Simon and Schuster.
- Kuo, C. C., Glover, F., & Dhir, K. S. (1993). Analyzing and modeling the maximum diversity problem by zero-one programming. *Decision Sciences*, 24(6), 1171-1185. DOI: <https://doi.org/10.1111/j.1540-5915.1993.tb00509.x>
- Maina, E. M., Oboko, R. O., & Waiganjo, P. W. (2017). Using machine learning techniques to support group formation in an online collaborative learning environment. *International Journal of Intelligent Systems & Applications*, 9(3), 26-33. DOI: 10.5815/ijisa
- Macêdo, P. H., Santos, W. B., & Maciel, A. M. (2020). Análise de perfis de engajamento de estudantes de ensino a distância. *RENOTE*, 18(2), 326-335.
- Marinho, J. and Souza, D. (2022). ActivePlan: Uma Abordagem para Formação de Grupos de Estudantes com Perfis Heterogêneos para Uso de Práticas Ativas de Aprendizagem, Estudo submetido a Revista Brasileira de Informática na Educação – RBIE.
- Monteverde, I., Amaral, G., Ramos, D., do Nascimento, P., Gadelha, B., & Oliveira, E. (2017, October). M-cluster: Uma ferramenta de recomendação para formação de grupos em ambientes virtuais de aprendizagem. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)* (Vol. 28, No. 1, p. 1657). DOI: <http://dx.doi.org/10.5753/cbie.sbie.2017.1657>

- Monteverde, I., Ramos, D., Amaral, G., Gadelha, B., & Oliveira, E. (2018, October). Framework Conceitual para Formação de Grupos de Alunos utilizando Trilhas de Aprendizagem em um Ambiente Virtual de Aprendizagem. In Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE) (Vol. 29, No. 1, p. 1673).DOI: <http://dx.doi.org/10.5753/cbie.sbie.2018.1673>
- Moran, J. (2015). Mudando a educação com metodologias ativas. Coleção mídias contemporâneas. Convergências midiáticas, educação e cidadania: aproximações jovens, 2(1), 15-33.
- Moran, J. M. (2007). A educação que desejamos: novos desafios e como chegar lá. Papirus Editora..[GS Search]
- Moubayed, A., Injadat, M., Shami, A., & Lutfiyya, H. (2020). Student engagement level in an e-learning environment: Clustering using k-means. American Journal of Distance Education, 34(2), 137-156. DOI:<https://doi.org/10.1080/08923647.2020.1696140>
- Nalli, G., Amendola, D., Perali, A., & Mostarda, L. (2021). Comparative Analysis of Clustering Algorithms and Moodle Plugin for Creation of Student Heterogeneous Groups in Online University Courses. Applied Sciences, 11(13), 5800. DOI: <https://doi.org/10.3390/app11135800>
- Oliveira, P. L. S., Rodrigues, R. L., Ramos, J. L. C., & Silva, J. C. S. (2022). Identificação de Pesquisas e Análise de Algoritmos de Clusterização para a Descoberta de Perfis de Engajamento. Revista Brasileira de Informática na Educação, 30, 01-19.
- Oliveira, P. L. S., Rodrigues, R. L., Ramos, J. L. C., & Silva, J. C. S. (2020, November). Uma Análise de Algoritmos de Clusterização para Descoberta de Perfis de Engajamento. In Anais do XXXI Simpósio Brasileiro de Informática na Educação (pp. 1012-1021). SBC.
- Pachane, G. G., & de Aguiar Pereira, E. M. (2004). A importância da formação didático-pedagógica e a construção de um novo perfil para docentes universitários. Revista Iberoamericana de Educación, 35(1), 1-13.
- Perrenoud, P. (2015). Dez novas competências para ensinar. Artmed editora.
- Pereira, P., Cunha, J. L., Sales, G., & Freire, A. (2018, October). Análise de perfis de interação de alunos no ambiente virtual Moodle via agrupamento hierárquico. In Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)(Vol.29,No.1,p.1413).DOI: <http://dx.doi.org/10.5753/cbie.sbie.2018.1413>
- Pereira, A. J., Gomes, A. S., Primo, T. T., da Silva, R. M. A., Rodrigues, R. L., de Campos Filho, A. S., ... & de Melo Júnior, R. P. (2021, November). Identificação e caracterização de níveis de interação no ensino remoto de emergência na Educação Básica. In Anais do XXXII Simpósio Brasileiro de Informática na Educação (pp. 145-156).SBC. DOI:<https://doi.org/10.5753/sbie.2021.218498>.
- Pimentel, E. P., de França, V. F., & Omar, N. (2003, November). A identificação de grupos de aprendizes no ensino presencial utilizando técnicas de clusterização. In

Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE) (Vol. 1, No. 1, pp. 495-504).

Ramos, J. L. C., Santos, L. F. L., Silva, J. C. S., & Rodrigues, R. L. (2020, November). Identificação de perfis de interação de estudantes de educação a distância por meio de técnicas de agrupamentos. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação* (pp. 932-941). SBC.

Romero, C., Romero, J. R., & Ventura, S. (2014). A survey on pre-processing educational data. In *Educational data mining* (pp. 29-64). Springer, Cham.

Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53–65. DOI:10.1016/0377-0427(87)90125-7.

Souza, J. P. L., de Souza, D. Y., & Dutra, J. F. (2020). Predição precoce de problemas de desempenho de estudantes em modalidade de educação online: um estudo de caso no ensino médio integrado. DOI:<http://dx.doi.org/10.18265/1517-0306a2021id5182>