

Evolução Temporal de Perfis Escolares e Associações de Habilidades no SAEB: Uma Análise em Mossoró e Parnamirim

**Heitor Nunes Costa¹, Marcos Vinicius de Andrade Lima²,
Raul Benites Paradedá³, Dario José Aloise³**

¹Programa de Pós-Graduação em Ciência da Computação (PPgCC)
Universidade do Estado do Rio Grande do Norte (UERN)
Universidade Federal Rural do Semi-Árido (UFERSA)
Mossoró – RN – Brasil

²Universidade Federal do Ceará (UFC)
Campus de Russas – Russas – CE – Brasil

³Universidade do Estado do Rio Grande do Norte (UERN)
Campus Mossoró – Mossoró – RN – Brasil

heitor.costa91317@alunos.ufersa.edu.br, marcos.vinicius@ufc.br,
raulparadedada@uern.br, darioaloise@uern.br

Abstract. *This paper analyzes the evolution of school profiles in Mossoró and Parnamirim using microdata from the Sistema de Avaliação da Educação Básica across five biennial cycles between 2011 and 2019. The study combines K-Means clustering and association rule mining through FP-Growth on Mathematics descriptors. The results show greater stability of intermediate school profiles in Mossoró, whereas Parnamirim presents greater polarization and structural fragility after 2015. The identified associations indicate that learning deficits occur in dependency chains among skills. The findings reinforce the usefulness of Educational Data Mining for more precise educational diagnostics and support for educational public management.*

Resumo. *Este artigo analisa a evolução de perfis escolares em Mossoró e Parnamirim a partir de microdados do Sistema de Avaliação da Educação Básica em cinco ciclos bienais entre 2011 e 2019. O estudo combina clusterização K-Means e mineração de regras de associação via FP-Growth sobre descritores de Matemática. Os resultados mostram maior estabilidade dos perfis intermediários em Mossoró, enquanto Parnamirim apresenta maior polarização e fragilidade estrutural após 2015. As associações identificadas indicam que os déficits de aprendizagem ocorrem em cadeias de dependência entre habilidades. Os achados reforçam a utilidade da mineração de dados educacionais para diagnósticos mais precisos e apoio à gestão pública educacional.*

1. Introdução

A análise da qualidade da educação é um tema central para formulação de políticas públicas e melhoria institucional. Em contextos onde há grande heterogeneidade socioeconômica e demográfica, entender como escolas se agrupam em termos de desem-

penho pode revelar desigualdades estruturais e sinalizar necessidades de intervenção [Silva 2025].

Embora os indicadores educacionais do Rio Grande do Norte (RN) tenham avançado na última década, esse progresso permanece desigualmente distribuído. Diagnósticos da Universidade Federal do Rio Grande do Norte (UFRN) mostram que, embora o Índice de Desenvolvimento da Educação Básica (IDEB) tenha aumentado de cerca de 2,5 em 2005 para 5,0 em 2019, as desigualdades estruturais persistem e continuam a desafiar a gestão pública [UFRN 2022]. Essa heterogeneidade opera dentro dos próprios territórios, dificultando ações de gestão [Gomes and Melo 2021].

O avanço das técnicas de EDM (do inglês, *Educational Data Mining*) tem permitido que instituições educacionais explorem grandes volumes de dados para extrair padrões relevantes de aprendizagem, desempenho e comportamento [Romero and Ventura 2010]. Nesse contexto, abordagens de mineração de dados têm ganhado destaque por sua capacidade de revelar estruturas ocultas e relações não triviais nos dados educacionais, oferecendo novas possibilidades de análise ainda pouco exploradas na literatura [Romero and Ventura 2013].

Embora estudos pontuais sobre desigualdades escolares sejam recorrentes, análises que capturem a dinâmica temporal dessas desigualdades permanecem raras, sobretudo em realidades como a do RN. Este trabalho avança nessa direção ao rastrear a evolução dos agrupamentos escolares em Mossoró e Parnamirim ao longo de cinco ciclos de aplicação da avaliação em larga escala do Sistema de Avaliação da Educação Básica (SAEB), utilizando mineração de dados educacionais em perspectiva longitudinal. Adicionalmente, complementa a análise de clusterização com a mineração de regras de associação via FP-Growth, identificando quais descritores da Matriz de Referência de Matemática falham de forma recorrente e associada ao longo do tempo.

Este artigo responde à seguinte questão: como evoluíram os perfis de desempenho e equidade das escolas de Mossoró e Parnamirim em cinco ciclos bienais entre 2011 e 2019, e quais padrões de déficit matemático podem ser identificados de forma associada ao longo desse período? Para respondê-la, aplicamos K-Means longitudinal e mineração de regras via FP-Growth sobre microdados do SAEB.

O trabalho apresenta três contribuições principais: (i) propõe uma metodologia de análise longitudinal de perfis escolares baseada em K-Means aplicada a cinco ciclos do SAEB, com harmonização de *clusters* ao longo do tempo para acompanhar trajetórias de desempenho e equidade; (ii) realiza um diagnóstico comparativo inédito entre as redes de Mossoró e Parnamirim, evidenciando padrões distintos de desigualdade com implicações para a gestão educacional; e (iii) complementa a análise com regras de associação via FP-Growth em Matemática, identificando habilidades não dominadas e suas dependências, de modo a apoiar intervenções pedagógicas mais precisas.

2. Fundamentação Teórica

2.1. Avaliação em Larga Escala

As avaliações em larga escala no Brasil, como o SAEB, constituem um dos principais instrumentos para diagnóstico da qualidade educacional no país [Brasil 2021b]. O SAEB é aplicado pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira

(INEP) em ciclos bienais, avaliando competências em Língua Portuguesa e Matemática nos 5º e 9º anos do Ensino Fundamental e na 3ª série do Ensino Médio.

Esses dados são utilizados para monitorar desigualdades, apoiar políticas públicas, orientar práticas pedagógicas e compor índices como o IDEB [Alves and Soares 2013]. A prova de Matemática do SAEB, foco deste estudo, avalia competências alinhadas à Matriz de Referência da disciplina [Brasil 2021a]. Suas questões são construídas com base na Teoria de Resposta ao Item (TRI), assegurando comparabilidade das proficiências entre anos e edições, condição essencial para análises longitudinais. A escala de proficiência varia de 0 a 500 pontos e indica, de forma crescente, o domínio das habilidades esperadas para cada etapa de ensino.

2.2. Mineração de Dados Educacionais

A área de EDM vem crescendo desde a década de 2000, combinando estatística, aprendizado de máquina e análise educacional para revelar padrões em bases de dados acadêmicos [Baker 2010]. A EDM tem sido usada amplamente para prever desempenho estudantil, identificar fatores de risco, detectar padrões ocultos e apoiar tomada de decisão institucional.

A clusterização é uma das técnicas centrais em EDM, permitindo agrupamentos naturais de estudantes, escolas ou municípios. O algoritmo K-Means, introduzido por MacQueen em 1967, é um dos mais populares devido à sua simplicidade, eficiência e capacidade de lidar com grandes conjuntos de dados [MacQueen 1967]. Aplicações educacionais de K-Means incluem agrupamento de estudantes por desempenho, comportamento, engajamento ou análise institucional [Wulandari et al. 2020].

2.3. Mineração de Regras de Associação e FP-Growth

A mineração de regras de associação é uma técnica de EDM que identifica relacionamentos frequentes entre itens em grandes bases de dados, sendo formalizada com o algoritmo Apriori [Agrawal and Srikant 1994]. Uma regra de associação assume a forma $X \Rightarrow Y$, onde X e Y são conjuntos de itens disjuntos, indicando que a ocorrência de X implica, com determinada probabilidade, a ocorrência de Y . As métricas fundamentais são:

- **Suporte:** frequência relativa do conjunto $\{X \cup Y\}$ nos dados - $\text{sup}(X \Rightarrow Y) = P(X \cup Y)$;
- **Confiança:** probabilidade condicional de Y dado X - $\text{conf}(X \Rightarrow Y) = P(Y | X)$;
- **Lift:** razão entre a confiança observada e a esperada por acaso - $\text{Lift}(X \Rightarrow Y) = \frac{P(Y|X)}{P(Y)}$, sendo o principal indicador de relevância da associação.

O algoritmo Frequent Pattern Growth (FP-Growth), proposto por Han, Pei e Yin (2000), supera o Apriori ao eliminar a geração explícita de candidatos, comprimindo a base de dados em uma estrutura de árvore compacta denominada FP-Tree. Isso reduz drasticamente o número de varreduras necessárias sobre os dados e o consumo de memória, tornando-o especialmente adequado para bases esparsas e de grande volume [Han et al. 2000]. No contexto educacional, o FP-Growth permite identificar quais habilidades ou descritores curriculares tendem a ser não dominados em conjunto pelos estudantes, revelando cadeias de dependência entre competências que análises isoladas não capturam [Lima 2023].

3. Trabalhos Relacionados

Para identificar estudos relevantes envolvendo EDM e técnicas de agrupamento aplicadas ao desempenho escolar, foi conduzida uma busca bibliográfica simples nas bases Google Scholar, IEEE Xplore e SciELO, utilizando a expressão: (“*educational data mining*” OR “*mineração de dados educacionais*”) AND (“*cluster analysis*” OR “*clusterização*” OR “*agrupamento*”) AND (“*school performance*” OR “*desempenho escolar*”).

A busca retornou 30 artigos, dos quais foram selecionados 4 estudos com base nos seguintes critérios de inclusão: (i) aplicação direta de técnicas de clusterização ou mineração de regras de associação; e (ii) uso de dados de avaliações educacionais em larga escala. Foram excluídos artigos de revisão sistemática e trabalhos cujo foco era exclusivamente previsão de desempenho individual sem análise de perfis institucionais como um todo.

[Nagaswetha et al. 2022] aplicaram o K-Means para identificar padrões de rendimento entre alunos, agrupando-os em três categorias: alto, médio e baixo desempenho. [Wulandari et al. 2020] combinaram K-Means com o classificador Naïve Bayes para estruturar um modelo híbrido de agrupamento e previsão de desempenho acadêmico.

No campo de regras de associação aplicadas à educação, estudos recentes demonstram a eficácia do FP-Growth na identificação de padrões de erros em avaliações padronizadas, permitindo orientar intervenções pedagógicas focalizadas [Sousa and Lima 2025, Costa and Lima 2025]. Esses estudos reforçam a crescente adoção de métodos quantitativos avançados para revelar padrões em avaliações educacionais, motivando a aplicação de técnicas similares às escolas municipais de Mossoró e Parnamirim.

4. Metodologia

A presente pesquisa adota uma abordagem quantitativa longitudinal, trabalhando com variáveis numéricas (médio ponderada de proficiência, peso amostral e medidas estatísticas derivadas) ao longo de cinco ciclos avaliativos e aplicando técnicas matemáticas e estatísticas para identificar padrões temporais. O estudo utiliza a abordagem de *Knowledge Discovery in Databases* (KDD), ilustrada na Figura 1, que consiste em um processo de múltiplas etapas envolvendo seleção, pré-processamento, transformação, mineração de dados e interpretação de padrões [Fayyad et al. 1996].

Esta pesquisa respeita integralmente a LGPD (Lei nº 13.709/2018), utilizando exclusivamente dados públicos, anonimizados e disponibilizados oficialmente pelo INEP em formato de microdados.

4.1. Seleção dos Dados

Foram selecionados os microdados referentes ao desempenho de estudantes do 9º ano do Ensino Fundamental na avaliação de Matemática do SAEB dos anos de 2011, 2013, 2015, 2017 e 2019. O recorte geográfico restringiu-se às redes municipais de ensino das cidades de Mossoró e Parnamirim, no RN.

A escolha de Mossoró e Parnamirim justifica-se por sua relevância demográfica, econômica e educacional. Excluindo Natal, são os dois municípios mais populosos do RN, mas apresentam contextos territoriais distintos: Parnamirim integra a Região Metropolitana de Natal, enquanto Mossoró é o principal polo de desenvolvimento do interior.




Figura 1. Etapas do KDD.

A comparação entre essas redes permite analisar a influência dessas diferentes dinâmicas territoriais sobre as desigualdades no desempenho escolar.

A base de dados bruta, extraída dos arquivos TS_ALUNO_9EF, contém registros individualizados por aluno. Para a construção do modelo, foram selecionadas as variáveis essenciais descritas no Quadro 1.

Quadro 1. Dicionário das variáveis selecionadas dos microdados do SAEB.

Variável	Descrição
ID_ESCOLA	Código único de identificação da escola (INEP). Utilizado como chave de agregação.
PROFICIENCIA_MT_SAEB	Nota de proficiência em Matemática do aluno na escala SAEB. Variável principal de desempenho.
PESO_ALUNO_MT	Peso estatístico atribuído a cada aluno. Utilizado para garantir a representatividade da amostra na população.

4.2. Pré-Processamento

O pré-processamento garantiu a qualidade dos dados nos cinco anos analisados, removendo registros inconsistentes e valores nulos nas variáveis de proficiência. Identificou-se uma anomalia nos microdados do INEP, com valores na ordem de 10^{15} , corrigida por normalização pelo fator escalar 10^{15} para adequação à escala do SAEB (0 a 500). A correção foi validada pela equivalência com os resultados oficiais do IDEB e INEP. Também foram removidas escolas com menos de 5 alunos avaliados, evitando vieses estatísticos na formação dos *clusters*.

4.3. Transformação

Nesta fase, os dados foram agregados do nível do aluno para o nível da escola. Para cada unidade escolar E_i , calcularam-se duas *features* utilizando o peso amostral w_{ij} (PESO_ALUNO_MT) de cada aluno j : a média ponderada de proficiência (μ_i), conforme a Equação (1), e o desvio-padrão intra-escolar ponderado (σ_i), conforme a Equação (2).

$$\mu_i = \frac{\sum_{j=1}^n w_{ij} x_{ij}}{\sum_{j=1}^n w_{ij}} \quad (1)$$

$$\sigma_i = \sqrt{\frac{\sum_{j=1}^n w_{ij} (x_{ij} - \mu_i)^2}{\sum_{j=1}^n w_{ij}}} \quad (2)$$

onde x_{ij} é a proficiência do aluno j e o denominador $\sum w_{ij}$ preserva a representatividade do desenho amostral do SAEB. Por fim, aplicou-se padronização *Z-score* (StandardScaler) para evitar que a magnitude da proficiência domine o desvio-padrão no cálculo da distância Euclidiana do K-Means.

4.4. Mineração de Dados - Clusterização K-Means

A etapa de clusterização identificou agrupamentos naturais de escolas com base em suas características de desempenho e desigualdade interna, utilizando o algoritmo K-Means.

A definição do número ideal de clusters foi realizada por meio de uma abordagem híbrida, combinando critérios quantitativos e qualitativos. Aplicou-se o método do cotovelo (*Elbow Method*), que analisa a redução da inércia (*Within-Cluster Sum of Squares* - WCSS) em função do número de *clusters* [Kassambara 2017]. A curva de inércia para valores de k entre 2 e 10 apresentou ponto de inflexão claro em $k = 4$ (Gráfico 1), onde o ganho marginal de compactação diminuía significativamente. Esse resultado foi validado pelo coeficiente de silhueta (*Silhouette Score*), que atingiu seu valor máximo (0,52) para $k = 4$, refletindo estruturação moderada dos clusters, com boa separação entre grupos e homogeneidade interna [Kaufman and Rousseeuw 1990]. Adicionalmente, a tipologia dos perfis Elite, Desempenho Consistente, Médio com Desigualdade e Baixo Desempenho mostrou-se alinhada com a literatura sobre estratificação escolar [Nagaswetha et al. 2022].




Gráfico 1. Método do Cotovelo para Definição de k .

Harmonização Longitudinal. Como o K-Means é executado independentemente para cada ciclo avaliativo, os rótulos gerados a cada ano são aleatórios e não comparáveis

diretamente entre edições. Para rastrear trajetórias institucionais ao longo do tempo, adotou-se um procedimento de harmonização baseado na ordenação dos centróides finais, aplicado após a convergência do algoritmo anualmente.

O procedimento opera em duas etapas: Primeiro, os quatro centróides (μ_k, σ_k) obtidos em cada ciclo são ordenados pela média de proficiência μ_k (decrescente) e, em caso de empate, pelo desvio-padrão σ_k (crescente). Segundo, os rótulos A, B, C e D são atribuídos de forma fixa a essa ordenação, correspondendo respectivamente aos perfis Elite, Desempenho Consistente, Médio com Desigualdade e Baixo Desempenho, conforme a Tabela 1. Esse critério garante que a escola atribuída ao perfil A em 2013 e em 2017 ocupe, em ambos os anos, o centróide de maior média, tornando a comparação entre ciclos semanticamente válida e não uma simples troca de etiqueta. Para assegurar a estabilidade das soluções, o K-Means foi executado com 30 inicializações aleatórias distintas ($n_init=30$) e semente fixa ($random_state=42$), adotando-se o resultado de menor inércia *intra-cluster*.

Interpretação dos Perfis. A etapa de mineração resultou na identificação de quatro perfis escolares distintos. A interpretação semântica dos grupos baseou-se na análise dos centróides finais calculados pelo K-Means, conforme a Tabela 1. A rotulação seguiu a lógica de quadrantes de desempenho (Média) versus equidade (Desvio-Padrão).

Tabela 1. Centróides finais dos *clusters* identificados.

<i>Cluster</i>	Média μ	Desv.-Pad. σ	Perfil Atribuído
A	273,06	42,62	Elite
B	238,45	44,94	Desempenho Consistente
C	236,84	54,20	Médio com Desigualdade
D	227,53	35,58	Baixo Desempenho

Com base nesses valores, os perfis foram definidos:

- **Cluster A (Elite):** Reúne as escolas com as maiores médias de proficiência ($\mu \approx 273$). O desvio-padrão controlado indica que o alto desempenho é generalizado entre os alunos, caracterizando ilhas de excelência acadêmica.
- **Cluster B (Desempenho Consistente):** Com médias próximas a 238, este grupo se destaca pela equidade ($\sigma \approx 45$). Sugere processo pedagógico mais homogêneo, onde a escola garante aprendizado básico para a maioria dos estudantes, sem deixar muitos para trás.
- **Cluster C (Médio com Desigualdade):** Perfil mais crítico para a gestão pública. Médias intermediárias ($\mu \approx 237$) mascaram o alto desvio-padrão ($\sigma > 54$), revelando profunda disparidade interna e segregação intraescolar.
- **Cluster D (Baixo Desempenho):** Menores médias ($\mu \approx 228$) e menor desvio-padrão ($\sigma \approx 36$). Essa “homogeneidade na precariedade” indica que a dificuldade de aprendizado é sistêmica e aponta para problemas estruturais graves.

4.5. Mineração de Dados - FP-Growth (Regras de Associação)

Complementarmente à clusterização, aplicou-se o algoritmo FP-Growth para identificar padrões recorrentes de não domínio de descritores da Matriz de Referência de Matemática

do SAEB. O FP-Growth foi escolhido em razão de sua eficiência computacional sobre bases esparsas [Han et al. 2000], característica típica de dados de avaliações padronizadas.

Construção das transações. Para cada ciclo avaliativo, cada aluno foi representado como uma transação composta pelo conjunto de descritores associados aos itens que respondeu incorretamente. Formalmente, um descritor D_d integra a transação do aluno j se este errou ao menos um item vinculado a D_d em qualquer dos blocos respondidos. Respostas ausentes ou inválidas (marcadas com . ou *) foram desconsideradas. Transações vazias (alunos sem nenhum erro registrado) foram excluídas da base. Esse mapeamento foi realizado cruzando as respostas individuais (TX_RESP_BLOCO) com o gabarito e os metadados de cada item (ID_DESCRITOR, GABARITO) provenientes do arquivo TS_ITEM disponibilizado pelo INEP.

Parametrização. O algoritmo foi configurado com suporte mínimo de 0,25 (25% dos alunos) e confiança mínima de 0,80, visando extrair apenas associações relevantes. Como critério adicional, foram mantidas apenas regras com $lift > 1,5$, indicando associações superiores ao acaso. O suporte mínimo foi calculado sobre o total de alunos da rede municipal em cada ciclo, e não por turma, pois o desenho amostral do SAEB, baseado na TRI e em cadernos rotacionados, inviabiliza análises em nível de sala de aula. A agregação dos dados municipais garante cobertura de todos os descritores da Matriz de Referência de Matemática, permitindo identificar padrões estruturais de coocorrência de erros. Assim, um suporte de 25% representa defasagens compartilhadas por pelo menos um quarto dos estudantes da rede analisada.

A estrutura de uma FP-Tree gerada a partir desse mapeamento de transações pode ser visualizada na Figura 2.




Figura 2. Exemplo ilustrativo de FP-Tree construída a partir de transações de alunos.

Os resultados foram classificados em quatro categorias interpretativas:

- **Superados:** descritores que deixaram de aparecer como consequentes nas regras ao longo da série, indicando superação da fragilidade;
- **Persistentes Críticos:** presentes em ≥ 4 edições consecutivas, revelando déficits estruturais profundos;
- **Persistentes:** presentes em 3 edições, indicando recorrência sem atingir o limiar crítico;

- **Emergentes:** surgidos a partir de 2017, sinalizando novas fragilidades ou mudanças na composição da prova.

Os scripts, bases derivadas e resultados estão disponíveis em repositório anônimo para fins de revisão: https://osf.io/2pmfd/overview?view_only=fb182ff4bf5b4c2aa79e52eda6fcf3b1

5. Resultados

A análise temporal da clusterização das escolas municipais de Mossoró e Parnamirim entre os anos selecionados de 2011 e 2019 revelou padrões dinâmicos de desempenho e equidade que transcendem as análises estáticas tradicionais. Esta seção apresenta os resultados em quatro dimensões: evolução da distribuição anual dos *clusters*, trajetória da proficiência média por perfil, trajetórias institucionais representativas e padrões de associação de descritores identificados pelo FP-Growth.

5.1. Evolução da Distribuição dos *Clusters*

Como mostrado no Gráfico 2, em Mossoró, predominam de forma estável os *clusters* intermediários B e C, que reúnem 70–80% das escolas, com leve aumento do *cluster* C após 2017, indicando maior desigualdade interna. Em Parnamirim, há polarização mais evidente: o *cluster* A permanece em 10–15% das escolas, enquanto o *cluster* D cresce após 2015, sinalizando maior vulnerabilidade educacional. Assim, Mossoró lida sobretudo com desigualdades intraescolares, enquanto Parnamirim apresenta um sistema mais segmentado entre alto e baixo desempenho.




Gráfico 2. Evolução da distribuição das escolas entre os clusters identificados.

5.2. Trajetória da Proficiência Média por *Cluster*

Como mostrado no Gráfico 3, em Mossoró, todos os *clusters* cresceram, mas em ritmos distintos: o *cluster* A manteve alta e contínua ascensão, enquanto o *cluster* D avançou pouco e permaneceu sempre abaixo dos demais. Em Parnamirim, os *clusters* B e C exibiram oscilações, indicando menor estabilidade. Em ambos os municípios, a distância entre A e D permaneceu ampla, evidenciando desigualdades persistentes. O *cluster* C apresentou desempenho médio inferior ao B em toda a série, mostrando que maior desigualdade interna tende a reduzir a proficiência média.




Gráfico 3. Comparação das trajetórias de proficiência média entre clusters.

5.3. Trajetórias Ilustrativas por Município

Em Mossoró, observa-se maior consistência nas trajetórias: a escola com melhor desempenho em 2011 manteve-se no *cluster* A até 2015, caiu para o *cluster* C em 2017 e recuperou o nível de Elite em 2019, enquanto a de pior desempenho evoluiu de forma contínua do *cluster* D (2011–2015) para o C (2017) e o B (2019). Em Parnamirim, as trajetórias são mais instáveis: a escola inicialmente melhor posicionada oscilou entre os *clusters* C e A, retornando ao C e sem sustentar a excelência, ao passo que a de pior desempenho avançou do *cluster* D para o B entre 2011 e 2017, mas recuou ao C em 2019, indicando dificuldades em consolidar os ganhos (ver Gráfico 4).




Gráfico 4. Trajetória das escolas com melhor e pior desempenho.

5.4. Padrões de Associação de Descritores - FP-Growth

A aplicação do FP-Growth sobre os cinco ciclos do SAEB revelou padrões consistentes de co-ocorrência de não domínio de descritores matemáticos em ambos os municípios. O Quadro 2 sintetiza os principais achados por categoria interpretativa.

Descritores Superados. O descritor D17 (Números racionais na reta numérica) é o único caso de superação bilateral confirmada: apareceu como consequente frequente em 2011 e 2015 em ambas as redes, desaparecendo em 2017 e 2019. Em Mossoró, D2 (Figuras bidimensionais/tridimensionais) foi adicionalmente superado após 2011.

Descritores Persistentes Críticos. O descritor D14 (Noções de volume) figura como o problema mais grave da década em ambos os municípios, aparecendo como consequente em quatro edições consecutivas (2011–2017) e desaparecendo apenas em

Quadro 2. Descritores identificados pelo FP-Growth por categoria e município.

Categoria	Mossoró	Parnamirim
Superados	D17: Racionais; D2: Figuras 2D/3D	D17: Racionais
Persist. críticos (≥ 4)	D14: Volume (2011–17); D29: Proporção (2011,15–19)	D14: Volume (2011–17); D21: Repr. racional (2013–19)
Persistentes (3)	D9: Coord. cartesianas; D21: Racional; D37: Tabelas/gráficos; D28: Porcentagem; D10: Triângulo	D29: Proporção; D28: Porcentagem; D37: Tabelas/gráficos; D3: Triângulos
Emergentes (2017–19)	D13: Área; D24: Decimais; D30: Expressões; D36: Sistemas (pico 121)	D13: Área; D24: Decimais; D16: Inteiros; D34: Função ($\text{lift} > 2,2$)

2019. Em Mossoró, D29 (Variações proporcionais diretas/inversas) também se classifica como persistente crítico, presente em quatro das cinco edições. Em Parnamirim, D21 (Representações de número racional) é persistente crítico de 2013 a 2019 (quatro ciclos consecutivos), revelando uma fragilidade estrutural específica dessa rede em representação numérica.

Descritores Persistentes. Ambas as redes compartilham D28 (Porcentagem), D29 (Proporção) e D37 (Tabelas e gráficos) como descritores recorrentes em três ou mais edições. Em Mossoró, destacam-se ainda D9 (Coordenadas cartesianas) e D10 (Relações métricas no triângulo retângulo), este último crescendo de 2015 a 2019. Em Parnamirim, D3 (Propriedades de triângulos) é persistente de 2015 a 2019.

Descritores Emergentes. D13 (Área de figuras planas) e D24 (Representações decimais dos racionais) emergiram simultaneamente em ambas as redes a partir de 2017, sugerindo origem sistêmica, possivelmente mudanças no peso dos descritores na prova ou lacunas curriculares anteriores. D24 apresentou *lift* superior a 1,9 quando associado a D3 e D16. Em Mossoró, D36 (Sistemas de equações do 1º grau) registrou o pico da série (121 regras em 2017), sinalizando crise pontual severa. Em Parnamirim, D34 (Função por tabela/gráfico) emergiu com o maior *lift* do ano ($> 2,2$), indicando associação muito forte.

Os padrões compartilhados entre os dois municípios são sintetizados no Quadro 3, constituindo a base para recomendações de intervenção regional conjunta.

Quadro 3. Padrões de descritores compartilhados identificados pelo FP-Growth.

Descritor	Habilidade	Padrão compartilhado
D14	Noções de volume	Persistente crítico em ambos (2011–2017); desaparece em 2019
D17	Racionais na reta numérica	Superado em ambos; único caso bilateral confirmado
D13	Área de figuras planas	Emergente simultâneo em 2017; origem sistêmica provável
D28	Porcentagem	Persistente em ambos ao longo de toda a série
D29	Variações proporcionais	Persistente em ambos; crítico em Mossoró

Um achado relevante do FP-Growth é que as falhas de aprendizagem apresentam uma estrutura reticulada, com descritores interdependentes, conforme indicado pelas métricas de suporte, confiança e *lift* da Tabela 2. Assim, dificuldades em proporcionalidade (D29) impactam a interpretação de tabelas e gráficos (D37), lacunas em números racionais (D21) afetam cálculos de volume (D14), fragilidades em relações métricas no

triângulo retângulo ($D10$) comprometem áreas de figuras planas ($D13$), e o não domínio associado de propriedades de triângulos ($D3$) e inteiros na reta ($D16$) reflete-se em falhas em representações decimais ($D24$). Esses padrões reforçam que intervenções isoladas têm eficácia limitada, sendo mais adequadas ações voltadas a blocos de habilidades relacionadas.

Tabela 2. Regras de associação para as principais cadeias de erros.

Resultados	Antecedente/s	Consequente/s	Confiança (%)	Suporte (%)	Lift
Mossoró	D29	D37	84,20	31,50	1,95
Mossoró	D10	D13	81,15	26,80	2,10
Parnamirim	D21	D14	82,50	28,40	1,75
Parnamirim	D3 e D16	D24	80,50	25,20	1,90

6. Considerações Finais

O presente trabalho analisou a evolução dos perfis escolares de Mossoró e Parnamirim nos ciclos bienais do SAEB, combinando K-Means e FP-Growth. Os resultados indicam trajetórias distintas: Mossoró apresentou maior estabilidade nos perfis intermediários, com desigualdades principalmente intraescolares, enquanto Parnamirim evidenciou maior polarização e crescimento do perfil de Baixo Desempenho após 2015. Em ambos os municípios, a distância entre os perfis Elite (A) e Baixo Desempenho (D) permaneceu elevada, indicando que os avanços de proficiência não reduziram significativamente as desigualdades educacionais.

A análise pelo FP-Growth organizou as fragilidades de aprendizagem em quatro categorias. Em **Superações**, destaca-se o D17 (racionais na reta) em ambas as redes e o D2 em Mossoró. Nos **Problemas recorrentes**, figuram o D14 (volume), D29 (proporção) em Mossoró e D21 (racionais) em Parnamirim, além de D28 e D37, evidenciando dependências estruturais em rede (ex.: $D29 \Rightarrow D37$ e $D21 \Rightarrow D14$). Nos **Problemas emergentes**, surgem a partir de 2017 o D13 (área) e o D24 (decimais) bilateralmente, o D36 em Mossoró e o D34 em Parnamirim. Como **Implicações para a gestão**, recomenda-se: estruturar intervenções por blocos de habilidades interdependentes, focar em desigualdades intraescolares em Mossoró e em déficits estruturais em Parnamirim e realizar monitoramento preventivo das habilidades emergentes (D13, D24).

Metodologicamente, a combinação de análise longitudinal de *clusters* com regras de associação mostrou-se complementar e eficaz, revelando trajetórias institucionais e padrões curriculares não captados por análises estáticas. Como perspectivas futuras, sugere-se ampliar o estudo para outras redes e etapas, incluir variáveis contextuais (como formação docente e infraestrutura) e investigar os efeitos da pandemia nas trajetórias dos *clusters* e descritores.

Apesar das contribuições, o estudo apresenta limitações. O recorte em Mossoró e Parnamirim restringe a generalização para outros contextos. A análise considera apenas desempenho e dispersão, sem incluir fatores como nível socioeconômico, características docentes e infraestrutura, o que reduz seu poder explicativo. Além disso, o K-Means é sensível à inicialização e pode não captar estruturas complexas. Por fim, os dados vão até 2019, não contemplando os impactos da COVID-19, ainda não avaliados nessas redes.

Declaração sobre uso de Inteligência Artificial

Neste artigo, foram utilizadas as ferramentas de Inteligência Artificial (IA) Claude Sonnet 4.6 (Anthropic) para auxiliar na organização lógica da estrutura do documento, para apoio na revisão gramatical e linguística, incluindo verificação de concordância verbal, em conformidade com a Portaria CNPq nº 2.664/2026. Os autores revisaram integralmente o trabalho e assumem total responsabilidade pelo conteúdo aqui presente.

Referências

- Agrawal, R. and Srikant, R. (1994). Fast algorithms for mining association rules. In *Proceedings of the 20th International Conference on Very Large Data Bases (VLDB)*, pages 487–499, San Francisco, CA, USA. Morgan Kaufmann.
- Alves, M. T. G. and Soares, J. F. (2013). Contexto escolar e indicadores educacionais: condições desiguais para a efetivação de uma política de avaliação educacional. *Educação e Pesquisa*, 39(1):211–228.
- Baker, R. S. J. D. (2010). Data mining for education. In *International Encyclopedia of Education*. Elsevier, Oxford, 3 edition.
- Brasil (2021a). Matriz de referência de matemática: SAEB. Technical report, Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), Brasília.
- Brasil (2021b). Sistema de avaliação da educação básica (SAEB): Documento básico. Technical report, Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), Brasília.
- Costa, J. A. R. S. and Lima, M. V. d. A. (2025). Análise comparativa dos resultados da prova de Matemática do SAEB nas capitais do Nordeste do Brasil no ano de 2019. *Regae: Revista de Gestão e Avaliação Educacional*, page e90533.
- Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P. (1996). From data mining to knowledge discovery in databases. *AI Magazine*, 17(3):37–54.
- Gomes, M. A. and Melo, F. (2021). Evolução e desigualdades no financiamento da educação no RN (1996–2019). In *Anais do Encontro Nacional de Economia*.
- Han, J., Pei, J., and Yin, Y. (2000). Mining frequent patterns without candidate generation. In *Proceedings of the ACM SIGMOD International Conference on Management of Data*, pages 1–12.
- Kassambara, A. (2017). *Practical Guide to Cluster Analysis in R*. STHDA.
- Kaufman, L. and Rousseeuw, P. J. (1990). *Finding Groups in Data: An Introduction to Cluster Analysis*. John Wiley & Sons, Hoboken, NJ.
- Lima, M. V. d. A. (2023). *(Re)estruturação do modelo de planejamento das ações de formação continuada em serviço de professores na rede municipal de Fortaleza: novas possibilidades por meio da ciência de dados educacionais*. Tese de doutorado, Universidade Estadual do Ceará, Fortaleza.
- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, pages 281–297, Berkeley, CA, USA. University of California Press.

- Nagaswetha, R., Kumar, S., Patel, V., and Sharma, N. (2022). Data mining for student performance analysis by clustering k-means algorithm. In *Proceedings of the International Conference on Innovative Computing and Communications*.
- Romero, C. and Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics – Part C: Applications and Reviews*, 40(6):601–618.
- Romero, C. and Ventura, S. (2013). Data mining in education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3(1):12–27.
- Silva, M. L. d. M. (2025). Desigualdades educacionais no Brasil: uma análise por clusterização de indicadores educacionais e desempenho escolar.
- Sousa, G. B. d. and Lima, M. V. d. A. (2025). Um estudo comparativo da análise dos erros nos descritores do spaece entre Fortaleza e o interior do Ceará com uso do algoritmo fp-growth. *RENOTE*, 23(1):560–571.
- UFRN (2022). Desigualdades educacionais: Diagnóstico aponta avanços e desafios no ensino do RN. Technical report, Agência de Comunicação da UFRN, Natal.
- Wulandari, D. A. N., Susanto, R., and Wijaya, T. (2020). Educational data mining for student academic prediction using k-means clustering and naïve bayes classifier. In *Proceedings of the International Conference on Electrical Engineering and Informatics*.