



ANÁLISE DA CORRELAÇÃO ENTRE QUANTIDADE DE MATRÍCULAS E IMPACTO ACUMULADO UTILIZANDO MODELOS DE MACHINE LEARNING

Ricardo Loureiro Soares¹ – ricardo.loureiro@uft.edu.br

Telma Reijane Pinheiro da Costa¹ – telmarpc@uft.edu.br

Fernando Jorge Ebrahim Lima e Silva¹ - fernando.ebrahim@uft.edu.br

Prof. Dr. Marcelo Lisboa¹ – m.lisboa@uft.edu.br

Prof. Dr. George França dos Santos¹ – george.f@uft.edu.br

¹ Universidade Federal do Tocantins – UFT – Palmas, TO, Brasil

Resumo. Neste estudo, examinamos a relação entre a quantidade de matrículas de alunos com deficiência na educação básica brasileira e o impacto acumulado de políticas públicas de inclusão. Utilizamos uma combinação de métodos de machine learning, como regressão linear múltipla, Random Forest e Gradient Boosting, para analisar dados longitudinais coletados ao longo de vários anos. Os resultados apontam que políticas com impacto considerado "Transformador" ou "Forte" têm uma correlação significativa com o aumento das matrículas. Entretanto, políticas categorizadas como "Neutro" ou "Leve" mostraram ter um efeito limitado. Embora este estudo foque na influência das políticas públicas, sublinhamos a importância de analisar também fatores externos como campanhas de conscientização e infraestrutura escolar. Concluímos que uma abordagem multifatorial é necessária para entender completamente a eficácia das iniciativas de educação inclusiva no Brasil.

Palavras-chave: Educação inclusiva, Políticas públicas, Machine learning, Modelos de regressão.

1. INTRODUÇÃO

No Brasil, o direito à educação é assegurado pela Constituição Federal e reforçado por uma série de legislações, como a Lei de Diretrizes e Bases da Educação (LDB) 9.394/96 e a Lei Brasileira de Inclusão da Pessoa com Deficiência. Essas leis consagram o princípio da igualdade e estabelecem que todos os indivíduos, independentemente de suas habilidades, têm direito a uma educação de qualidade. Em especial, o sistema legal brasileiro promove a inclusão de pessoas com deficiência na rede regular de ensino, exigindo adaptações curriculares, tecnológicas e pedagógicas para garantir sua plena participação e aprendizado.

A discussão sobre a inclusão educacional de pessoas com deficiência é vital, dada a necessidade de um ambiente de aprendizado que vá além da simples matrícula desses alunos.

Entretanto, apesar dos avanços legislativos, diversos obstáculos, como falta de recursos financeiros e humanos, resistência cultural, e deficiências na formação dos profissionais, ainda persistem.

Diante deste cenário, este estudo tem como foco realizar uma análise temporal da educação inclusiva no Brasil, com ênfase na acessibilidade e participação de alunos com deficiência em escolas regulares. A pergunta de pesquisa que norteia este trabalho é:

Como as políticas públicas de inclusão afetam a quantidade de matrículas de alunos com deficiência na educação básica brasileira?

Para abordar essa questão, foram utilizados dados do Instituto Brasileiro de Geografia e Estatística (IBGE), e aplicadas técnicas de machine learning para modelar e prever as matrículas destes alunos. Os objetivos específicos incluem:

- Revisar a evolução histórica e os marcos legais da educação inclusiva no Brasil e internacionalmente.
- Avaliar as políticas públicas existentes utilizando uma escala de impacto baseada na hierarquia e descrição das leis.
- Empregar métodos de machine learning, como regressão linear múltipla, Random Forest e Gradient Boosting, para analisar a eficácia dessas políticas.
- Verificar a precisão, relevância e consistência dos resultados obtidos, comparando-os com a literatura existente no campo da educação inclusiva.

2. REVISÃO DA LITERATURA

Iniciar com uma visão geral dos conceitos e teorias é crucial para entender o panorama da inclusão educacional. Ao longo dos anos, debates significativos surgiram para alinhar as práticas educacionais com as legislações e normas... (Brasil, 2015; Diniz, 2007; Sassaki, 1997; Skrtic, 1991; Slee, 2011).

Para entender a inclusão de uma forma mais tangível, é importante explorar as perspectivas práticas. Professores, pais, e especialmente estudantes com deficiência, oferecem visões únicas sobre o que realmente significa ser incluído (Rodrigues, 2022).

O suporte legal para a inclusão é fornecido por uma série de legislações, iniciando com a Constituição Federal de 1988 e abrangendo leis como a LBI 13.146/2015, bem como tratados internacionais (ONU, 2006; PNE 2014-2024).

Além do suporte legal, existem políticas públicas que implementam e concretizam esses princípios e diretrizes. Essas incluem programas como o Programa de Implantação de Salas de Recursos Multifuncionais, o Programa Escola Acessível, e o Programa BPC na Escola.

A Inteligência Artificial está emergindo como uma ferramenta potencialmente poderosa para personalizar a educação e torná-la mais inclusiva. Programas de IA podem analisar padrões de aprendizagem e adaptar metodologias para atender às necessidades específicas dos alunos com deficiência (Dawod; Bell, 2022; Fayza Megahed, 2019; Ingavélez-Guerra *et al.*, 2022; Karagianni; Drigas, 2023; Kelleher; Namee; D'Arcy, 2020).

3. METODOLOGIA

A mineração de dados busca extrair informações pertinentes e significativas de grandes volumes de dados (Han; Kamber; Pei, 2012). Este campo interdisciplinar abrange técnicas da estatística, inteligência artificial e aprendizado de máquina. A inteligência artificial é uma área da ciência da computação que se dedica a criar sistemas capazes de realizar tarefas que normalmente requerem inteligência humana, como aprender, raciocinar e resolver problemas (Russel; Norvig, 2016). O aprendizado de máquina, um ramo da inteligência artificial, foca na modelagem de métodos de aprendizado computacional (Fan; Cheng; Li, 2021). Ele habilita

computadores a aprenderem a partir de dados, reconhecendo padrões e conexões, os quais podem ser usados para realizar previsões e tomadas de decisão baseadas em conhecimentos prévios. Este campo emprega vários algoritmos e técnicas estatísticas para treinar modelos com dados, permitindo-lhes executar tarefas como classificação, regressão, agrupamento, entre outras. A modelagem preditiva, por sua vez, usa o aprendizado de máquina para antecipar tendências e padrões futuros a partir de dados passados (Mahoto *et al.*, 2023). Neste estudo, empregaremos a mineração de dados para identificar informações-chave sobre a inclusão de alunos com deficiência na educação básica brasileira. Utilizaremos o aprendizado de máquina para desenvolver modelos que possam explicar e prever o número de matrículas de alunos com deficiência nas instituições brasileiras. E, recorrendo à modelagem preditiva, abordaremos o problema como uma questão de regressão, uma vez que nossa variável dependente é numérica.

A análise de dados se baseia nas seguintes variáveis:

- **Variável dependente:** quantidade de matrículas de alunos com deficiência na educação básica brasileira. Esta variável representa o resultado que queremos explicar e prever, com base na nossa pergunta de pesquisa. Para medir esta variável, utilizaremos os dados do Censo Escolar, divulgados pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP).
- **Variáveis independentes:** políticas públicas voltadas à inclusão de alunos com deficiência na educação brasileira. Estas variáveis representam os fatores que podem influenciar o resultado da variável dependente. Para medir estas variáveis, utilizaremos as legislações e normas que regulamentam e implementam a educação inclusiva no Brasil, desde a Constituição Federal de 1988 até a atualidade. Para aprofundar nossa análise e obter análises mais significativas, introduzimos uma estrutura de avaliação do impacto das políticas públicas. Esta estrutura foi meticulosamente elaborada considerando dois aspectos essenciais: as hierarquias das leis e a descrição detalhada de cada uma. A compreensão das nuances e importância de cada legislação foi vital para atribuir uma avaliação justa e precisa. Foi com base nesses critérios que chegamos às categorias e escalas de impacto conforme mostrado na tabela 1.

Tabela 1 - Categorias e escalas de impacto.

Neutro (0)	A legislação ou política não demonstra nenhum impacto perceptível ou mensurável.
Leve (1)	A legislação ou política tem um impacto mínimo e pode afetar apenas áreas ou grupos muito específicos.
Moderado (2)	A legislação ou política tem um impacto perceptível e mensurável, afetando áreas ou grupos específicos de maneira notória, mas sem ser abrangente em toda a sociedade ou setor educacional.
Significativo (3)	A legislação ou política tem um impacto razoável, sendo notável, mas não abrangente ou transformador em grande escala
Forte (4)	A legislação ou política tem um bom impacto e afeta de forma positiva uma ampla gama de áreas ou grupos.
Transformador (5)	A legislação ou política tem um impacto excelente, levando a mudanças revolucionárias ou reformulando completamente setores, grupos ou a sociedade como um todo.

O uso desta estrutura visa não apenas quantificar o impacto das políticas públicas, mas também qualificar e contextualizar as mesmas. Assim, podemos ter uma visão mais abrangente e profunda das políticas públicas que serão analisadas neste estudo.

O propósito deste estudo é analisar a correlação entre o número de matrículas de alunos com deficiência na educação básica brasileira e as políticas públicas de inclusão, considerando seu impacto potencial e descritivo. Queremos entender como a implementação e a efetividade dessas políticas influenciam a integração educacional desses alunos.

Para isso, escolhemos a regressão linear como a técnica analítica adequada, por várias razões. Primeiro, nossa variável dependente (quantidade de matrículas) é numérica, o que torna a regressão linear apropriada para estabelecer relações entre as variáveis independentes (políticas públicas) e a variável dependente. Segundo, a regressão linear é reconhecida por sua simplicidade e robustez (Philippe Gagnon; Alain Desgagné; Mylène Bédard, 2020). Ela permite avaliar de forma clara e objetiva a relação entre as variáveis independentes e dependentes, bem como a significância estatística das variáveis independentes. Terceiro, ao integrar a classificação do impacto potencial das políticas na análise, podemos captar melhor as nuances da influência de cada política.

Dessa forma, nosso estudo visou oferecer percepções valiosas sobre a trajetória da educação inclusiva no Brasil, considerando as políticas públicas de inclusão. Por meio desta abordagem, esperamos contribuir para a literatura existente, bem como subsidiar futuras decisões e estratégias no âmbito da educação inclusiva.

Neste estudo, empregamos uma série de métodos estatísticos e analíticos para entender o impacto das políticas públicas na inclusão de alunos com deficiência na educação básica no Brasil. A pesquisa começou com a coleta de dados de fontes confiáveis, cobrindo um período de 10 anos. As variáveis independentes incluíram diferentes tipos de políticas públicas, categorizadas com base no seu impacto percebido, e a variável dependente focou no número de matrículas de alunos com deficiência.

Três modelos estatísticos distintos — Regressão Linear Múltipla, Random Forest e Gradient Boosting — foram usados para analisar a relação entre as políticas e as matrículas. Cada modelo foi cuidadosamente avaliado com base no erro quadrático médio (MSE) para garantir sua adequação. Os coeficientes da regressão linear indicaram a força e direção da relação entre as políticas públicas e as matrículas, e todos os coeficientes significativos foram validados estatisticamente ao nível de 5%.

O valor de R-quadrado foi também calculado para quantificar o quanto da variação nas matrículas poderia ser explicado pelas políticas inclusivas.

4. RESULTADOS

Neste capítulo, são apresentados os resultados obtidos a partir da análise dos dados, utilizando-se da regressão linear para compreender a relação entre as políticas públicas voltadas para a inclusão e a quantidade de matrículas de alunos com deficiência na educação básica brasileira.

A partir dos dados coletados, observou-se que houve um aumento gradual no número de matrículas de alunos com deficiência ao longo dos anos. Em particular, houve um pico notável após a introdução de políticas com impacto avaliado como “Transformador”, conforme podemos visualizar na Fig.1.




Figura 1 - Número de matrículas de alunos na educação especial e Impacto Acumulado das políticas ao longo dos anos

Na Fig. 2, pode-se visualizar os coeficientes obtidos pela regressão linear, onde é estabelecido a relação entre cada política pública e a quantidade de matrículas. Políticas com impacto “Transformador” e “Forte” apresentaram os coeficientes mais altos, indicando uma forte correlação positiva com o aumento das matrículas. Em contraste, políticas com impacto avaliado como “Neutro” ou “Leve” apresentaram coeficientes próximos de zero, sugerindo um impacto mínimo nas matrículas.




Figura 2 - Legislações por Ano e Impacto Potencial

Todos os coeficientes das políticas avaliadas como “Moderado”, “Significativo”, “Forte” e “Transformador” foram estatisticamente significativos ao nível de 5%. Isso indica que essas políticas têm uma influência real e mensurável sobre o número de matrículas de alunos com

deficiência na educação básica brasileira. O nível de 5% significa que há apenas 5% de probabilidade de rejeitar a hipótese nula (de que não há relação entre as variáveis) quando ela é verdadeira (Hair, 2009).

O valor de R-quadrado obtido foi de 0,78, sugerindo que 78% da variação na quantidade de matrículas pode ser explicada pelas políticas públicas inclusivas consideradas no modelo. O R-quadrado é uma medida de ajuste do modelo, que indica a proporção da variância da variável dependente que é explicada pelas variáveis independentes (Shaw *et al.*, 2023).

Para entender melhor a relação entre as políticas de inclusão e o aumento das matrículas, testamos três modelos de regressão: regressão linear múltipla, Random Forest e Gradient Boosting. A regressão linear múltipla é um modelo que estima a relação entre uma variável dependente contínua e várias variáveis independentes (Zhang, 2023). O Random Forest é um modelo que combina várias árvores de decisão, cada uma treinada com um subconjunto aleatório dos dados, e faz a média das suas previsões (Hasan Putra *et al.*, 2023). O Gradient Boosting é um modelo que constrói sequencialmente árvores de decisão, cada uma corrigindo os erros das anteriores, e faz uma combinação ponderada das suas previsões (Konstantinov; Utkin, 2020). A Tabela 2 mostra os modelos que foram avaliados com base no erro quadrático médio (MSE), que mede a diferença entre os valores reais e os valores previstos pelo modelo.

Tabela 2 – Resultados obtidos pelos modelos de regressão

Modelo de regressão linear múltipla	MSE: 3,111,365,209.26
Modelo Random Forest	MSE: 699,569,756.22
Modelo Gradient Boosting	MSE: 5,833.02

O modelo Gradient Boosting apresentou o menor erro quadrático médio (MSE), tornando-se o modelo mais adequado para esta análise. Esse resultado enfatiza a potência do Gradient Boosting na modelagem de dados complexos, principalmente quando há interações não lineares entre as variáveis, conforme ilustrado na Fig. 3.




Figura 3 - Comparação das Previsões dos Modelos

5. DISCUSSÃO

Os resultados evidenciam a importância das políticas públicas de inclusão na promoção da educação inclusiva no Brasil. Em particular, políticas com impactos mais significativos, como "Transformador" e "Forte", parecem desempenhar um papel crucial no aumento das matrículas de alunos com deficiência.

A correlação positiva entre políticas robustas e o aumento das matrículas sugere que esforços concentrados e bem direcionados do governo podem levar a avanços significativos na inclusão educacional. No entanto, é importante lembrar que, embora a correlação forneça compreensões sobre a relação entre as variáveis, ela não estabelece causalidade. A implementação e o impacto real de cada legislação podem variar ao longo do tempo e entre diferentes regiões do país.

Para uma análise mais aprofundada e precisa, é necessária uma revisão detalhada de cada legislação, bem como informações adicionais sobre o contexto e os resultados práticos de cada uma. Além das legislações, é crucial considerar outros fatores que possam influenciar o número de matrículas, tais como campanhas de conscientização, treinamento de professores, evolução social em relação à inclusão, infraestrutura das escolas e políticas públicas específicas para a educação especial.

Por outro lado, políticas com impactos "Neutro" ou "Leve" parecem ter pouco efeito nas matrículas. Isso ressalta a necessidade de reavaliação e possíveis reformulações nessas políticas para torná-las mais efetivas.

6. CONCLUSÃO

O presente estudo buscou analisar a correlação entre a quantidade de matrículas de alunos com deficiência na educação básica brasileira e o impacto acumulado de políticas públicas de inclusão. Utilizando métodos de machine learning, como regressão linear múltipla, Random Forest e Gradient Boosting, o estudo revelou compreensões importantes sobre a eficácia das políticas públicas na promoção da educação inclusiva no Brasil.

Os resultados indicam que políticas com impacto categorizado como "Transformador" ou "Forte" têm uma correlação significativa com o aumento das matrículas de alunos com deficiência. Isso sugere que ações governamentais bem direcionadas e robustas podem efetivamente contribuir para a inclusão educacional desses alunos. O valor de R-quadrado de 0,78 reforça essa observação, indicando que 78% da variação na quantidade de matrículas pode ser explicada pelas políticas públicas inclusivas consideradas no modelo.

Por outro lado, políticas com impacto avaliado como "Neutro" ou "Leve" mostraram ter um efeito limitado sobre as matrículas, o que aponta para a necessidade de revisão e aprimoramento dessas iniciativas. O estudo também destaca a importância de considerar fatores externos, como campanhas de conscientização e infraestrutura escolar, que podem influenciar a eficácia das políticas públicas.

O modelo Gradient Boosting se mostrou o mais eficaz na modelagem dos dados, com o menor erro quadrático médio (MSE), destacando a complexidade e as interações não lineares entre as variáveis estudadas. Isso sugere que futuras pesquisas podem se beneficiar do uso de métodos de machine learning mais avançados para uma análise ainda mais precisa.

Em síntese, este estudo contribui para a compreensão da eficácia das políticas públicas de inclusão na educação básica brasileira e ressalta a importância de uma abordagem multifatorial para entender completamente o cenário da educação inclusiva no país. Os resultados obtidos podem servir como base para futuras pesquisas e para o desenvolvimento de políticas públicas mais eficazes, visando a uma educação verdadeiramente inclusiva.

Dada a importância do tema e os resultados promissores obtidos, recomenda-se que estudos futuros explorem mais profundamente os fatores externos e contextuais que podem influenciar

a eficácia das políticas públicas, bem como avaliem o impacto dessas políticas em diferentes regiões do Brasil.

REFERÊNCIAS

- Bai, Xiaomei *et al.* Educational Big Data: Predictions, Applications and Challenges. *Big Data Research*, [s. l.], v. 26, p. 100270, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214579621000873>.
- BRASIL. Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (Inep). Resumo Técnico: Censo Escolar da Educação Básica 2022. Disponível em: <https://inepdata.inep.gov.br/analytics/saw.dll?Dashboard>
- BRASIL. Presidência da República. Lei nº 13.146, de 06 julho de 2015. Institui a Lei Brasileira de Inclusão da Pessoa com Deficiência (Estatuto da Pessoa com Deficiência). Brasília, 2015. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/l13146.htm.
- Dawod, Zainb; Bell, David. Enhancing the Learning of Special Educational Needs children with Dynamic Content Annotations. [S. l.: s. n.], 2022.
- Diniz, Débora. O que é deficiência. 1ªed. [S. l.]: Editora Brasiliense, 2007. E-book. Disponível em: https://www.fcm.unicamp.br/fcm/sites/default/files/2016/page/texto_o_que_e_deficiencia-2.pdf.
- Fan, Kunjie; Cheng, Lijun; LI, Lang. Artificial intelligence and machine learning methods in predicting anti-cancer drug combination effects. *Briefings in Bioinformatics*, [s. l.], v. 22, n. 6, p. bbab271, 2021. Disponível em: <https://doi.org/10.1093/bib/bbab271>.
- Fayza Megahed. Artificial intelligence applications and Developing the Life Skills for Students with Special Needs: A future Look. *International Journal of research in Educational Sciences*, [s. l.], v. 3, n. 1, 2019. Disponível em: <https://iafh.net/index.php/IJRES/article/view/161>. Acesso em: 6 set. 2023.
- Goldhaber, Dan; Wolff, Malcolm; Daly, Timothy. Assessing the accuracy of elementary school test scores as predictors of students' high school outcomes. Working paper no. 235-0520. National Center for Analysis of Longitudinal Data in Education Research (CALDER), [s. l.], 2020.
- Hair, Jr., Joseph F and Black, William C and Babin, Barry J and Anderson, Rolph E and Tatham, Ronald L. Análise Multivariada de Dados. 6ªed. [S. l.]: Bookman, 2009.
- Han, Jiawei; Kamber, Micheline; Pei, Jian. Data mining concepts and techniques third edition. University of Illinois at Urbana-Champaign Micheline Kamber Jian Pei Simon Fraser University, [s. l.], 2012.
- Hasan Putra, Purwa et al. Random forest and decision tree algorithms for car price prediction. *Jurnal Matematika Dan Ilmu Pengetahuan Alam LLDikti Wilayah 1 (JUMPA)*, [s. l.], v. 3, p. 81–89, 2023.
- Hilbert, Sven et al. Machine learning for the educational sciences. *Rev. Educ.*, [s. l.], v. 9, n. 3, 2021.
- Ingavélez-Guerra, Paola et al. Automatic Adaptation of Open Educational Resources: An Approach From a Multilevel Methodology Based on Students' Preferences, Educational Special Needs, Artificial Intelligence and Accessibility Metadata. *IEEE Access*, [s. l.], v. 10, p. 9703–9716, 2022.
- Karagianni, Eleni; Drigas, Athanasios. New Technologies for Inclusive Learning for Students with Special Educational Needs. *International Journal of Online and Biomedical Engineering (iJOE)*, [s. l.], v. 19, n. 05, p. 4–21, 2023. Disponível em: <https://online-journals.org/index.php/i-joe/article/view/36417>. Acesso em: 6 set. 2023.
- Kelleher, John D.; Namee, Brian Mac; D'ARCY, Aoife. *Fundamentals of Machine Learning for Predictive Data Analytics*, Second Edition. 2. ed. [S. l.]: The MIT Press, 2020.
- Konstantinov, Andrei V.; Utkin, Lev V. Gradient boosting machine with partially randomized decision trees. *CoRR*, [s. l.], v. abs/2006.11014, 2020. Disponível em: <https://arxiv.org/abs/2006.11014>.
- Mahoto, Naeem Ahmed et al. A machine learning based data modeling for medical diagnosis. *Biomedical Signal Processing and Control*, [s. l.], v. 81, p. 104481, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809422009351>.
- Philippe Gagnon; Alain Desgagné; Mylène Bédard. A New Bayesian Approach to Robustness Against Outliers in Linear Regression. *Bayesian Analysis*, [s. l.], v. 15, n. 2, p. 389–414, 2020. Disponível em: <https://doi.org/10.1214/19-BA1157>.
- Qin, Zhou. Research Progress on Educational Data Mining: A Survey. *Journal of Software*, [s. l.], 2015. Disponível em: <https://api.semanticscholar.org/CorpusID:63973497>.
- Rodrigues, David. Inclusão e educação : doze olhares sobre a educação inclusiva. [S. l.: s. n.], 2022. E-book. Disponível em: <https://app.bczm.ufrn.br/home/#/item/132813>.
- Russel, Stuart; Norvig, Peter. *Inteligência Artificial*. 3ªed. [S. l.]: Elsevier, 2016.
- Sassaki, Romeu Kazumi. *Inclusão: construindo uma sociedade para todos*. [S. l.: s. n.], 1997.
- Shaw, Mairead et al. r2mlm: An R package calculating R-squared measures for multilevel models. *Behavior Research Methods*, [s. l.], v. 55, n. 4, p. 1942–1964, 2023. Disponível em: <https://doi.org/10.3758/s13428-022-01841-4>.

- Skrtic, Thomas M. Behind special education : a critical analysis of professional culture and school organization / Thomas M. Skrtic.1991. Anais [...]. [S. l.: s. n.], 1991. Disponível em: <https://api.semanticscholar.org/CorpusID:141092202>.
- Slee, Roger. The Irregular School: Exclusion, Schooling and Inclusive Education. The Irregular School: Exclusion, Schooling and Inclusive Education, [s. l.], p. 1–220, 2011.
- Zhang, Borui. Variable and model selection method in linear regression for analysis. Applied and Computational Engineering, [s. l.], v. 6, p. 191–197, 2023.

ANALYSIS OF THE CORRELATION BETWEEN ENROLLMENT NUMBERS AND ACCUMULATED IMPACT USING MACHINE LEARNING MODELS.

Abstract: *In this study, we investigated the relationship between the enrollment numbers of students with disabilities in Brazilian basic education and the accumulated impact of public inclusion policies over the years. To understand this dynamic, we employed advanced machine learning techniques, including multiple linear regression, Random Forest, and Gradient Boosting. The findings indicated that policies with impacts categorized as "Transformative" and "Strong" exert a significant influence on increasing enrollments. However, policies with "Neutral" or "Light" impacts showed limited efficacy. Beyond the connection between policies and enrollments, we emphasize the need for a deeper analysis of the legislation and the consideration of external factors, such as awareness campaigns and school infrastructure. We conclude that for a comprehensive understanding of the promotion of inclusive education in Brazil, it's essential to consider the interaction between multiple factors and the accumulated impact of public policies over time.*

Keywords: *Inclusive education, Public policies, Machine learning, Regression models*