

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE CIÊNCIAS SOCIAIS APLICADAS
DEPARTAMENTO DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

LUCAS ANDRÉ DOS SANTOS

IMPACTOS DO ENSINO REMOTO NO APRENDIZADO DE ESTUDANTES
BRASILEIROS

PONTA GROSSA

2025

LUCAS ANDRÉ DOS SANTOS

IMPACTOS DO ENSINO REMOTO NO APRENDIZADO DE ESTUDANTES
BRASILEIROS

Dissertação apresentada como requisito parcial à
obtenção do título de Mestre em Economia, no
Programa de Pós-Graduação em Economia, Setor
de Ciências Sociais Aplicadas da Universidade
Estadual de Ponta Grossa.

Orientadora: Prof.^a Dr.^a Augusta Pelinski Raiher.

PONTA GROSSA

2025

S237 Santos, Lucas André dos
Impactos do ensino remoto no aprendizado de estudantes brasileiros / Lucas André dos Santos. Ponta Grossa, 2025.
79 f.

Dissertação (Mestrado em Economia - Área de Concentração: Economia),
Universidade Estadual de Ponta Grossa.

Orientadora: Profa. Dra. Augusta Pelinski Raiher.

1. Educação. 2. Pandemia. 3. Ensino remoto. 4. Propensity score matching.
I. Raiher, Augusta Pelinski. II. Universidade Estadual de Ponta Grossa. Economia.
III.T.

CDD: 330



UNIVERSIDADE ESTADUAL DE PONTA GROSSA
Av. General Carlos Cavalcanti, 4748 - Bairro Uvaranas - CEP 84030-900 - Ponta Grossa - PR - <https://uepg.br>

TERMO

LUCAS ANDRÉ DOS SANTOS

IMPACTOS DO ENSINO REMOTO NO APRENDIZADO DE ESTUDANTES BRASILEIROS

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Economia, da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Ponta Grossa, 28 de fevereiro de 2025

Dra Augusta Pelinski Raiher - Universidade Estadual de Ponta Grossa

Dr. Alysson Luiz Stege - Universidade Estadual de Ponta Grossa

Documento assinado digitalmente
gov.br MARINA SILVA DA CUNHA
Data: 28/02/2025 11:40:01-0300
Verifique em <https://validar.iti.gov.br>

Dra Marina Silva da Cunha - Universidade Estadual de Ponta Grossa



Documento assinado eletronicamente por **Augusta Pelinski Raiher, Professor(a)**, em 28/02/2025, às 10:27, conforme Resolução UEPG CA 114/2018 e art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **Alysson Luiz Stege, Professor(a)**, em 28/02/2025, às 11:03, conforme Resolução UEPG CA 114/2018 e art. 1º, III, "b", da Lei 11.419/2006.



A autenticidade do documento pode ser conferida no site <https://sei.uepg.br/autenticidade> informando o código verificador **2439136** e o código CRC **FA8DF710**.

AGRADECIMENTOS

Agradeço à Deus por minha vida.

Aos meus pais, por todo apoio durante o Mestrado. Por sempre acreditaram em mim, e incentivarem que eu corresse atrás dos meus sonhos.

À minha orientadora, Prof.^a Dr.^a Augusta Pelinski Raiher por toda ajuda durante a elaboração dessa dissertação. Por sempre ser atenciosa e presente nos momentos de dúvida.

Aos professores Alysson Luiz Stege e Marina Silva da Cunha, presentes na minha banca de defesa, por terem aceitado o convite e dedicado seu tempo na leitura e apontamentos da minha dissertação.

Ao Programa de Pós-Graduação em Economia da UEPG, e todos seus profissionais e colaboradores, por todas as oportunidades que tive nesses dois anos de Mestrado.

E, por fim, agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento por via de bolsa de estudo, que contribuiu de maneira fundamental para minha realização e conclusão do Mestrado.

“Uma criança, um professor, um livro e uma caneta podem mudar o mundo. Educação é a única solução.”

(Malala Yousafzai)

RESUMO

A educação formal é um elemento fundamental na formação do capital humano, desempenhando um papel importante na determinação de renda e superação das desigualdades. Nesse contexto, a eclosão da pandemia da Covid-19 impôs um grande desafio à aprendizagem em nível global, ao exigir a suspensão das atividades presenciais nas escolas, e a adoção do ensino remoto como alternativa. Assim, o objetivo dessa dissertação é avaliar o efeito da transição para o ensino remoto, imposta pela pandemia, no aprendizado de estudantes brasileiros de escolas públicas, comparando alunos de 2019 e 2021. Além disso, busca-se compreender como as desigualdades prévias no sistema educacional podem ter modulado os efeitos dessa transição, afetando de maneira desigual a qualidade e efetividade do ensino remoto entre diferentes grupos de alunos. Para isso, foram utilizados dados de provas e questionários do SAEB (Sistema Nacional de Avaliação da Educação Brasileira), a partir dos quais, foi estimado o efeito do ensino remoto no aprendizado dos alunos brasileiros por meio do *Propensity Score Matching*. Esse método permite o pareamento de estudantes com características semelhantes, garantindo uma comparação mais precisa entre os grupos analisados. Constatou-se perda considerável de aprendizagem dos alunos de 2021 (pós ensino remoto), quando comparados com alunos de 2019 (pré ensino remoto). Foi encontrado, ainda, evidências de que desigualdades educacionais e sociais existentes antes da pandemia tiveram papel relevante na potencialização da perda de aprendizagem.

Palavras-chave: Educação; pandemia; ensino remoto; *propensity score matching*.

ABSTRACT

Formal education is a fundamental element in the formation of human capital, playing an important role in income determination and overcoming inequalities. In this context, the outbreak of the Covid-19 pandemic imposed a major challenge to learning at a global level, by requiring the suspension of in-person activities in schools and the adoption of remote learning as an alternative. Thus, the objective of this dissertation is to evaluate the effect of the transition to remote learning, imposed by the pandemic, on the learning of Brazilian students in public schools, comparing students from 2019 and 2021. In addition, it seeks to understand how previous inequalities in the educational system may have modulated the effects of this transition, unequally affecting the quality and effectiveness of remote learning among different groups of students. To this end, data from tests and questionnaires from SAEB (Sistema Nacional de Avaliação da Educação Básica) were used, from which the effect of remote learning on the learning of Brazilian students was estimated through Propensity Score Matching. This method allows for the pairing of students with similar characteristics, ensuring a more accurate comparison between the groups analyzed. A considerable loss of learning was found among students in 2021 (post-remote learning), when compared to students in 2019 (pre-remote learning). Evidence was also found that educational and social inequalities that existed before the pandemic played a relevant role in increasing the loss of learning.

Keywords: Education; pandemic; remote learning; propensity score matching.

SUMÁRIO

1 INTRODUÇÃO.....	8
2 REVISÃO DE LITERATURA	12
2.1 Capital Humano e Crescimento Econômico	12
2.2 Determinantes do Desempenho Escolar: Discussão Teórica e Evidências Empíricas	14
2.3 Estudos empíricos acerca dos Impactos da Pandemia no Desempenho Escolar	19
3 METODOLOGIA	24
3.1 Base de Dados.....	24
3.2 <i>Propensity Score Matching</i> (PSM).....	25
4 COVID-19 E DESEMPENHO ESCOLAR DOS ESTUDANTES BRASILEIROS: ANÁLISE EMPÍRICA.....	34
4.1 Efeito do Ensino Remoto na Aprendizagem dos Alunos Brasileiros	40
5 CONSIDERAÇÕES FINAIS	44
REFERÊNCIAS.....	47
APÊNDICE A – GRÁFICOS DE BALANCEAMENTO DO PSM.....	53

1 INTRODUÇÃO

A educação formal, realizada em espaços específicos para a aquisição de conhecimento, como as escolas, é um elemento central da formação do capital humano, que, por sua vez, é um determinante do crescimento econômico. Com efeito, a partir da década de 1960, o capital humano foi incorporado aos modelos de crescimento econômico, inicialmente de forma quantitativa, com base na premissa de que o aumento nos anos de escolaridade teria efeitos positivos na renda individual, atuando diretamente na elevação da produtividade do trabalho e no desenvolvimento e difusão de tecnologia (Lucas, 1988; Romer, 1990).

No entanto, estudos mais recentes, como o Nakabashi e Salvato (2007), destacam que não apenas a quantidade, mas também a qualidade do capital humano é crucial na determinação do nível de renda e no crescimento econômico. Ao analisar os estados brasileiros, os autores controlaram o capital humano pelas diferenças de qualidade educacional e concluíram que um aumento nos anos de estudo, sem melhoria na qualidade, tem um impacto mais limitado na renda. Além disso, verificaram que a significância do capital humano se intensifica quando qualidade e quantidade são consideradas em conjunto, evidenciando que o efeito positivo da educação sobre a renda depende tanto da duração quanto da efetividade do aprendizado.

Raiher (2009) analisou a importância do Capital Humano na taxa de crescimento per capita das microrregiões paranaenses entre 1999 e 2006, analisando seus aspectos quantitativos e qualitativos. Os resultados mostraram que o capital humano teve efeito significativo na difusão de tecnologia apenas quando os elementos qualitativos foram considerados, reforçando que a qualidade do conhecimento acelera a difusão tecnológica.

Além disso, foi encontrada significância no efeito do capital humano sobre a renda per capita apenas quando considerado a qualidade da força de trabalho ou a qualidade e quantidade de capital humano em conjunto, sugerindo que, a quantidade de capital humano sozinha não foi capaz de influenciar a renda per capita das microrregiões paranaenses.

Esses estudos destacam a relevância da qualidade do capital humano, especialmente no que tange à qualidade educacional, como fator determinante no crescimento econômico regional. No caso do Brasil, os resultados do Programa Internacional de Avaliação de Estudantes (PISA), realizado pela Organização para a Cooperação e Desenvolvimento Econômico (OCDE), indicam uma baixa qualidade educacional, com o país posicionando-se abaixo da média dos países da OCDE em leitura, matemática e ciências (OCDE, 2023). Além disso, segundo o Inep (2023), com base nos dados do PISA de 2022, 73% dos estudantes

brasileiros não atingiram o nível básico em matemática, considerado pela OCDE o mínimo necessário para o exercício pleno da cidadania. Em leitura, 50% dos estudantes não alcançaram esse nível, enquanto em ciências o percentual foi de 55%. Esses dados revelam deficiências significativas que limitam o potencial do capital humano no Brasil.

Para reforçar os dados internacionais, a Prova SAEB (Sistema de Avaliação da Educação Básica) de 2019 – Anos Finais – demonstrou que, a porcentagem de alunos que atingiu o aprendizado considerado suficiente para sua etapa era bastante baixa. Com relação a grupos específicos, 24% de alunos de baixo nível socioeconômico alcançaram o aprendizado considerado adequado pelo Inep em português, e apenas 10% em matemática. O percentual para alunos de alto nível socioeconômico é 45% e 26% respectivamente. Na discriminação por raça, em matemática o percentual de alunos com aprendizado adequado que se auto identificaram como negros foi de 12%, brancos 25%, e indígenas 12%.

Nesse contexto, esses dados apontam para um déficit educacional significativo no Brasil, agravado por desigualdades no aprendizado entre alunos de diferentes raças e níveis socioeconômicos. Na visão de Hanushek e Woessmann (2020), o aprendizado é um processo dinâmico e contínuo, ou seja, se constrói sobre aprendizado anterior. Com efeito, interrupções no aprendizado de um aluno podem afetar sua trajetória escolar por muitos anos. Quando consideramos essa perspectiva, o período de ensino remoto, em razão da pandemia de Covid-19, pode ter consequências ainda mais sérias.

Com efeito, em dezembro de 2019, a OMS (Organização Mundial de Saúde) foi notificada sobre crescentes casos de pneumonia na cidade de Wuhan. Uma semana depois, foi identificada uma nova cepa de coronavírus, nomeado, a princípio, de nCoV, e, posteriormente recebeu o nome SARS-CoV-2, causador da Covid-19 (OPAS, 2020). Em março de 2020, a OMS declarou pandemia global, o que levou estados brasileiros a adotarem medidas preventivas, incluindo a suspensão das atividades educacionais presenciais. Concomitantemente, o Ministério da Educação (MEC), por meio da Portaria nº 343 de 17 de março de 2020, determinou a substituição das aulas presenciais por aulas remotas, utilizando meios digitais. Embora essa transição tenha sido necessária para conter o avanço do vírus, o ensino remoto pode ter intensificado as desigualdades educacionais, prejudicando especialmente estudantes com menos acesso a tecnologias e suporte adequado para a aprendizado à distância.

Ressalta-se que, embora essa transição para o ensino remoto tenha sido aprovada pelo MEC, Costa e Nascimento (2020) argumentam que, ninguém estava devidamente preparado para tanto, de forma que, sistemas educacionais, escolas, professores e alunos tiveram que se

adaptar rapidamente ao novo modelo de aulas. Em somatório a isso, a Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD-Contínua) no quarto trimestre de 2018, indicava que cerca de 14,9 milhões de domicílios não tinham acesso à internet. Isso significa que as escolas foram forçadas a adotar um modelo de ensino para o qual não estavam preparadas, ao mesmo tempo em que muitos alunos careciam tanto de recursos tecnológicos quanto de conhecimento para utilizá-los adequadamente.

Segundo relatório divulgado pelo Inep, 99,3% das escolas brasileiras suspenderam suas atividades presenciais durante a pandemia, durando em média 279 dias durante o ano letivo de 2020. (INEP, 2022). Essa interrupção prolongada se destaca em comparação com outros países. Dados da Unesco indicam que, no Chile e na Argentina, as escolas ficaram fechadas por 199 dias. No México, o período foi de 180 dias, e, no Canadá, de 163 dias. Em contraste, países como França e Portugal tiveram suspensões mais breves, com 43 e 67 dias, respectivamente. (UNESCO, 2022).

Em pesquisa realizada pelo Instituto Península (2021), com 2.557 entrevistados, um dos achados mais importantes foi que 85% dos professores acreditavam que o aprendizado com retorno das aulas presenciais seria abaixo do esperado.

Considerando a educação como um catalisador essencial para o crescimento econômico e a redução das desigualdades, juntamente com o atraso educacional do Brasil em comparação com outros países, e o prolongado período de suspensão do ensino presencial devido à pandemia de COVID-19, essa dissertação se questiona acerca do impacto da transição abrupta para o ensino remoto sobre o aprendizado dos estudantes brasileiros.

Ressalta-se que as disparidades na qualidade educacional entre o Brasil e outros países são acentuadas por desigualdades internas, que incluem variações na infraestrutura escolar, condição socioeconômica dos alunos, recursos didáticos e tecnológicos, dentre outros elementos. Essas diferenças internas, combinadas com os desafios impostos pela pandemia de COVID-19, podem ter resultado em impactos distintos no aprendizado entre os diversos grupos de estudantes no Brasil.

Nesse contexto, essa dissertação tem o objetivo de analisar o efeito da transição para o ensino remoto¹, imposta pela pandemia, no aprendizado de estudantes brasileiros de escolas públicas, comparando 2019 e 2021. Além disso, busca-se compreender como as desigualdades prévias no sistema educacional podem ter modulado os efeitos dessa transição, afetando de

¹ Ressalta-se aqui que o ensino remoto é referente apenas a modalidade emergencial adotada pelas escolas durante a pandemia, sendo conceitualmente diferente do EAD (Ensino a Distância) que é reconhecido como modalidade educacional desde 1996, e planejada pelos docentes desde o início.

maneira desigual a qualidade e efetividade do ensino remoto entre diferentes grupos de alunos. Para isso, inicialmente é analisada a distribuição espacial do aprendizado ao longo do Brasil antes e após o ensino remoto, identificando as desigualdades existentes; na sequência, é mensurado o efeito do ensino remoto no aprendizado dos estudantes, subdividindo-os em grupos específicos (por classe de renda e características da escola).

No Brasil, uma das principais avaliações que medem o aprendizado nos anos iniciais e finais de ensino é a Prova SAEB, que é aplicada aos estudantes do 5º e 9º ano do Ensino Fundamental, e do 3º ano do Ensino Médio, avaliando suas competências e habilidades em língua portuguesa e matemática. Isto posto, esta dissertação utiliza os resultados da Prova SAEB – anos finais (9º ano) – como medida do aprendizado dos estudantes brasileiros, nos anos de 2019 e 2021.

Por fim, cabe ressaltar que, as perdas acentuadas no aprendizado podem resultar em consequências duradouras para a economia e para o desenvolvimento nacional, exigindo intervenções estratégicas. Currie e Thomas (2001), por exemplo, observaram que a queda de 0,20 ponto em testes padronizados podia reduzir a probabilidade de emprego em 0,86 por cento. Portanto, os resultados deste estudo têm o potencial de orientar políticas educacionais urgentes e informar decisões estratégicas em níveis governamentais, tanto imediatos quanto de longo prazo.

Ademais, essa dissertação amplia a investigação sobre os impactos da pandemia na educação brasileira, diferenciando-se pelo uso do método *Propensity Score Matching* em uma escala nacional. Esse método proporciona uma avaliação precisa do impacto diferenciado da pandemia sobre os diversos estratos sociais e educacionais no Brasil. A análise emprega dados do SAEB dos anos de 2019 e 2021, permitindo a classificação dos alunos segundo critérios como condição socioeconômica e condições escolares, tornando mais específica a identificação de possíveis efeitos do ensino remoto no aprendizado dos alunos brasileiros.

Para isso, essa dissertação será composta de 5 seções, incluindo esta. Na segunda são apresentados os determinantes do desempenho escolar, trazendo também algumas evidências sobre o impacto da pandemia do desempenho escolar. Na terceira seção tem-se os elementos metodológicos. Na sequência será apresentado a análise dos resultados, seguido das considerações finais.

2 REVISÃO DE LITERATURA

Essa seção visa apresentar um compilado dos principais estudos na área da educação, em particular, os que dizem respeito aos determinantes do desempenho escolar e o impacto da pandemia na educação. Inicialmente, será revisada a literatura sobre a importância do capital humano para o crescimento econômico, contextualizado o papel central da educação nesse processo.

2.1 Capital Humano e Crescimento Econômico

A Teoria do Capital Humano emergiu no início da década de 1960, principalmente através dos trabalhos de Schultz (1961), Becker (1964) e Mincer (1974). Antes disso, o domínio do pensamento macroeconômico sobre crescimento era pautado em modelos exógenos, como o proposto por Solow em 1956, que vinculavam o crescimento econômico aos fatores de produção tradicionais – recursos naturais, capital e trabalho. No entanto, essa perspectiva começou a ser questionada à medida que países com rendimentos desproporcionais ao seu capital físico surgiram, indicando que, os modelos tradicionais não eram adequados para explicar aumentos de produtividade observados em certas regiões. Uma das explicações que ganhou protagonismo nesse cenário, foi a de melhoria da qualidade do trabalho, a partir da elevação da escolaridade média.

Schultz (1961) se debruçou no dilema acerca do crescimento das economias subdesenvolvidas, e, concluiu que, a melhoria do bem-estar da população mais pobre não dependia da terra, tecnologia ou do seu esforço, mas sim, do conhecimento. Dessa forma, a qualificação dos indivíduos advinda da educação, geraria incrementos de produtividade.

A contribuição de Mincer (1974) foi especialmente relevante ao estabelecer os anos de estudo como principal medida do capital humano. Em seu estudo, Mincer encontrou evidências de que diferenças nos salários poderiam ser significativamente explicadas por anos de estudo completos, e pela experiência do trabalhador. A Equação de Salários Minceriana tornou-se função genérica da determinação de salários, e foi replicada em mais de 100 países (Psacharopoulos; Patrinos, 2004).

A Teoria do Capital Humano defende a ideia de que, incrementos no investimento nacional em educação, gerariam incrementos na renda nacional, ou seja, aceleração do

crescimento econômico. No mesmo raciocínio, incrementos no investimento individual em educação e qualificação, gerariam incrementos na renda individual.

Lucas (1988) argumentava que os modelos de crescimento neoclássicos deveriam ser aprimorados com a inclusão do capital humano como um fator central na promoção de mudanças tecnológicas. O autor argumenta que, como a tecnologia é um bem público, e, por isso, disponível a todos os países, não poderia ser responsável pelas discrepâncias de crescimento. A diferença estava na acumulação individual de capital humano. O Modelo de Lucas introduziu a ideia da externalidade do capital humano, na forma de *spill-over*. Para o autor, os trabalhadores alocam parte do seu tempo na busca de novas habilidades – aumento do seu capital humano – e esse aumento de habilidade geraria maior remuneração futura. Além disso, Lucas admite a possibilidade de incremento no capital humano através do aprendizado dos trabalhadores no próprio processo de produção (*learning by doing*). Esse modelo explica que a não-convergência de todos os países para a mesma renda per capita, está vinculada às diferenças na acumulação de capital humano.

Já Romer (1990) propôs que, a tecnologia e o conhecimento sejam considerados intrínsecos ao processo de crescimento, ou seja, endógenos. O Modelo de Romer consiste em três setores, onde o setor de pesquisa utiliza capital humano e o conhecimento existente para produzir conhecimento novo (projetos para construção de novos bens); o setor de bens intermediários utiliza o conhecimento produzido pelo setor de pesquisa para produzir bens de capital que serão utilizados na produção de bens finais; e o setor de bens finais utiliza trabalho, capital humano e os bens de capital para produzir bens finais. O equilíbrio desse modelo se fundamenta na suposição de que os pesquisadores têm livre acesso ao estoque de conhecimento/tecnologia, isto é, a tecnologia é um bem não-rival. O fato de uma montadora utilizar certo processo de produção, não impede que outra montadora utilize o mesmo processo. Essa característica não-rival, permite que a tecnologia tenha retornos crescentes de escala. Dessa forma, o surgimento de novas ideias, através do setor de pesquisa, impulsionaria o crescimento, pois todos da economia se beneficiariam.

Assim, o capital humano teria três vias de impacto sobre o crescimento econômico: de forma direta, elevando a produtividade do trabalho; e indiretamente, por meio do desenvolvimento de tecnologias e da difusão de tecnologia (Nakabashi; Salvato, 2007).

A partir dessas proposições teóricas, se sucedeu uma grande gama de estudos empíricos que buscavam comprovar a relação entre educação e crescimento econômico. Dentre esses trabalhos, tem-se o de Barro (1991), o qual verificou, em um *cross-section* de 98 países, que dado o nível do PIB per capita inicial, o crescimento é positivamente relacionado com o

montante de capital humano inicial. Card e Krueger (1996) resumem que, a maioria das estimações do retorno marginal de um ano de estudo estão entre 6 e 10 por cento.

De acordo com Wilson (2002), embora existam problemas como a omissão do viés de habilidade, é bem aceito pela literatura que anos adicionais de estudo, aumentam a renda individual significativamente em termos estatísticos e econômicos.

Porém, medidas de anos de estudo podem não contemplar o que está de fato sendo aprendido na educação formal. Para preencher essa lacuna, o economista Eric Hanushek, referência em pesquisa educacional, realizou diversos trabalhos que usaram o desempenho de alunos em testes internacionais para dimensionar a qualidade da educação.

Hanushek e Kimko (2000) estimam o impacto da qualidade da educação, medida por testes de matemática e ciências, no crescimento econômico medido pela taxa de crescimento do PIB. Os resultados reportados foram de uma forte relação positiva, e, aparentemente causal, entre qualidade educacional e taxa de crescimento do PIB.

Jamison *et al.* (2007) reportaram a existência de uma relação entre a qualidade da educação e rendimento econômico como renda per capita. Ademais, concluíram que, os testes de matemática, aparentemente, medem um elemento do capital humano importante para o crescimento da renda per capita, que não é capturado pela quantidade de anos de estudo sozinha. Dependendo da situação, o aumento de um desvio-padrão na nota dos testes padronizados poderia estar associado com um aumento de 0,5 - 0,9 percentual na renda per capita anual. Os autores acreditam que, essas evidências suportam a ideia de que a qualidade educacional impacta a renda através de mudanças na taxa de progresso técnico.

2.2 Determinantes do Desempenho Escolar: Discussão Teórica e Evidências Empíricas

A discussão sobre determinantes do desempenho escolar ganhou destaque em 1966, com a publicação de um estudo seminal conduzido pelo professor James Coleman e diversos colaboradores, resultado de uma extensa pesquisa encomendada pelo Departamento de Educação dos Estados Unidos. De acordo com Brooke e Soares (2008), esse trabalho foi justificado pela apreensão com a qualidade da educação e com as oportunidades oferecidas pelo sistema educativo. Koslinski e Alves (2012) adicionam que, o estudo pretendia descrever a distribuição diferencial das oportunidades escolares entre jovens segundo raça, cor, origem nacional e religião, partindo da hipótese de que diferenças na infraestrutura e recursos pedagógicos das escolas seriam as principais fontes de desigualdade.

Os resultados de mais de três anos de pesquisa foram consolidados no relatório intitulado *“Equality of Education Opportunities”*, e, posteriormente, ficaram conhecidos como Relatório Coleman (Coleman et. al, 1966). Os dados utilizados foram levantados através de questionários aplicados em cerca de 4 mil escolas, para mais de 600 mil alunos e 60 mil professores. As perguntas para os docentes tinham relação com salário, experiência profissional, atitudes em relação a raças, entre outros tópicos, enquanto, os discentes responderam questionamentos sobre raça, sexo, nível socioeconômico e aprendizado.

Com relação a metodologia, foi utilizado um modelo *input-output*, onde, a partir de uma regressão linear múltipla, é calculado em que medida a variação das variáveis de entrada dos alunos, como origem social e variáveis de entrada das escolas, como infraestrutura, podem afetar o desempenho ou resultado dos alunos.

As conclusões do Relatório Coleman foram polêmicas ao afirmarem que, as diferenças estruturais entre as escolas tinham impactos marginais no desempenho dos alunos, frente ao grande fator de impacto que era a condição socioeconômica e a origem social dos alunos. Alves e Soares (2007) acreditam que, os achados do Relatório Coleman trouxeram um grande pessimismo pedagógico, pois concluíam que “as escolas não fazem diferença”.

Os dados do Relatório Coleman foram reanalisados por vários pesquisadores, que chegaram as mesmas conclusões. Um dos trabalhos mais relevantes dessa vertente foi o intitulado *“Inequality: A reassessment of the effects of family and schooling in America”* de Christopher Jencks et. al (1972), onde os autores concluíram que havia maiores diferenças educacionais entre alunos de uma mesma escola do que entre alunos de escolas diferentes, reforçando a ideia de que, o impacto das escolas é menor do que o impacto externo.

Uma outra publicação importante que reforça o Relatório Coleman é o seu contemporâneo Relatório Plowden. (1967) desenvolvido na Inglaterra, cujas conclusões foram de que as escolas tinham pequeno impacto no desempenho dos alunos.

A partir da década de 1970, passaram a surgir pesquisas que contrariaram e criticaram os resultados e a metodologia dos trabalhos apresentados anteriormente, de forma a argumentar que as escolas poderiam fazer diferença no desempenho dos alunos, e que, os modelos utilizados não consideravam a causalidade implícita e possíveis interações entre processos intraescolares e externos à escola. Brooke e Soares (2008) argumentam que uma das principais críticas ao Relatório Coleman e a pesquisas subsequentes foi a negligência em considerar as particularidades de cada escola na capacidade de transformar insumos em resultados significativos. Essa linha de pesquisa ficou conhecida como Teoria da Escola Eficaz.

Segundo Muijs (2006), a pesquisa em “Escola Eficaz” visava superar o pessimismo prevalecente sobre o impacto das escolas na educação e no desempenho dos alunos. O autor, ainda, pontua que esse movimento tinha o objetivo de estudar os fatores internos das escolas que poderiam levar a melhores desempenhos, independente da condição social dos alunos.

Scheerens (1990) apresenta cinco fatores intraescolares que influenciavam o desempenho dos alunos, de acordo com as primeiras pesquisas da Teoria da Escola Eficaz, sendo eles: liderança forte, ênfase na aquisição de habilidades básicas, ambiente seguro e organizado, altas expectativas no desempenho dos alunos, e, avaliação frequente do progresso dos alunos.

Um dos trabalhos que ganhou destaque nessa nova fase da pesquisa em desempenho educacional foi a publicação “*Fifteen Thousand Hours*” de Rutter et al. (1979), que leva esse nome - Quinze Mil horas - em referência a estimativa dos autores de quanto tempo durava os onze anos escolares obrigatórios em Londres. Mortimore (1998), um dos autores da publicação, escreveu, ao revisar o trabalho original, que, o objetivo da pesquisa era responder duas questões “escolas diferentes têm efeitos diferentes no progresso dos alunos?” e “o que faz com que algumas escolas tenham mais sucesso que outras?”.

Os autores utilizaram quatro medidas de resultado: presença, comportamento, resultados em exames públicos e taxa de delinquência em doze escolas públicas. Os resultados empíricos demonstraram que a escola explicava cerca de 20% da variação no desempenho dos alunos, e, argumentaram que, esse número era bastante relevante considerando as 15.000 horas que os alunos passavam na escola frente a maior quantidade de horas que eles passavam fora da escola.

A teoria da Escola Eficaz teve contribuições de diversos pesquisadores tais quais Hanushek (1970), Bloom (1976), Brookover (1978), Willms (1992). A definição mais usada para Escola Eficaz era aquela que faz seus alunos progredirem mais do que se esperaria, levando em conta seu nível socioeconômico e o ponto de partida em termos de desempenho (Mortimore et al., 1991).

As críticas à metodologia *input-output*, ganharam força com o surgimento de novas técnicas que permitiram analisar as variáveis relacionadas ao aluno e à escola em diferentes níveis. Além disso, o avanço computacional possibilitou o cálculo de modelos mais complexos, validando essas críticas e impulsionando o desenvolvimento de abordagens mais robustas. Esses modelos são conhecidos como regressão hierárquica ou multinível, e, permitem que, os dados educacionais sejam estruturados de maneira diferente, como por exemplo, os alunos agrupados em turmas, as turmas agrupadas em escolas, e as escolas organizadas por órgãos

administrativos. Dessa forma, o modelo teria quatro níveis hierárquicos, sendo os alunos o primeiro nível, as turmas o segundo, as escolas o terceiro, e, os órgãos administrativos o quarto.

No Brasil, as pesquisas direcionadas ao efeito da escola no desempenho dos alunos são, ainda, recentes, tendo origem a partir da década de 1990, quando o Instituto Nacional de Pesquisas Educacionais Anísio Teixeira (INEP) passou a disponibilizar os dados do Sistema de Avaliação da Educação Básica (SAEB).

Soares et al. (2004) analisando dados do SAEB e do PISA de 2003, estimaram que os efeitos das escolas públicas brasileiras no desempenho em matemática (controlando o nível socioeconômico dos alunos) varia entre 11% e 22% dependendo de série e disciplina.

Alves et al. (2007) utilizaram dados da prova Brasil, do Censo Escolar e referentes à remuneração e perfil dos professores para 649 escolas públicas de Goiás, com fins de avaliar o desempenho dos alunos. Os autores trabalharam com três fatores, sendo o primeiro, a origem socioeconômica dos alunos (renda familiar, posse de bens selecionados e instrução dos pais); o segundo, condições de oferta de ensino (infraestrutura das escolas); e o terceiro, os indicadores de resultado (notas nas provas de português e matemática). Em seguida, as escolas foram agrupadas conforme suas características de infraestrutura, e divididas em duas amostras de acordo com as notas da Prova Brasil (antiga denominação da Prova SAEB), de forma que, fossem analisados o melhor e o pior percentil de escolas, ou seja, as escolas que obtiveram 10% das maiores e 10% das piores notas. Por fim, foi feito um cruzamento entre os fatores, para verificar correlação entre eles. O principal resultado encontrado foi que escolas com grande número de alunos por sala apresentavam pior desempenho.

Andrade e Laros (2007) construíram um modelo multinível para o desempenho escolar, usando dos dados do SAEB de 2001, para os alunos do 3º ano do Ensino Médio do Brasil. Além do desempenho dos alunos nos testes, foram usadas variáveis de origem social e condição das escolas. Os resultados indicaram que 17% da variância do desempenho escolar podia ser explicada pelo nível da escola. Além disso, as variáveis com maior efeito referentes ao aluno foram atraso escolar e comparação do aluno com colegas, enquanto, referentes à escola foram recursos culturais agregado e atraso escolar agregado.

Araújo e Siqueira (2010) estudaram os determinantes do desempenho em matemática dos alunos da 4ª série do Brasil com os dados do SAEB e do Censo Escolar. A amostra conteve 40.963 alunos e 4.850 escolas, e o modelo desenvolvido foi um probit ordenado pelo critério do INEP de associação dos resultados obtidos com a capacidade cognitiva esperada de um aluno da 4ª série. Os principais resultados mostraram alta influência do contexto familiar. Os alunos do sexo feminino, autodeclarados negros e considerados mais pobres, apresentaram

desempenho inferior quando comparado aos demais. Com relação ao efeito escola, o estudo detectou impactos positivos no desempenho dos alunos de escolas caracterizadas por serem da rede privada, possuírem laboratórios de ciência e informática, quadra esportiva e estarem associadas ao programa TV Escola. O estudo também analisou diferenças regionais, e, nesse caso, indicou que alunos residentes na região Nordeste apresentaram melhores resultados nos testes de matemática.

No geral, a literatura em determinantes do desempenho escolar entende a existência de impactos tanto de fatores intraescolares quanto de fatores externos à escola. Para ilustrar essa relação, Machado et al. (2008) propõem a seguinte função de produção educacional:

$$Y = f(cBa, cBf, cBe, cBm, e) \quad (1)$$

Onde:

Y = desempenho dos alunos;

cBa = vetor de características dos alunos;

cBf = vetor de características da família;

cBe = vetor de características da escola;

cBm = vetor de características do município;

e = termo de erro aleatório.

Os autores indicam que, o desempenho pode ser medido pela proficiência, e as características dos alunos podem ser cor, gênero, idade, entre outros. No âmbito das famílias, pode se observar a escolaridade dos pais, renda e outras medidas de nível socioeconômico, como por exemplo, acesso a computadores. O vetor de características das escolas pode incluir variáveis referentes aos professores, como escolaridade, a infraestrutura da escola, o custo-aluno e demais insumos. Por fim, nas características municipais, os autores citam o PIB per capita municipal e indicadores de oferta de educação.

Além desses fatores, outros pesquisadores sugerem a relevância de outras variáveis, como por exemplo a violência. Ferreira e Oliveira (2013) avaliaram o impacto de oito indicadores de violência no desempenho dos alunos no Brasil. Os dados utilizados foram da prova SAEB de 2011 para as turmas do quinto e nono ano do Ensino Fundamental, e terceiro ano do Ensino Médio, e o desempenho foi medido pela nota no teste de matemática. O modelo desenvolvido foi um probit. Os resultados apontaram que a violência escolar reduz a probabilidade de o aluno alcançar um desempenho adequado. Foram encontradas, também,

evidências de que, diferenças de sexo minimizam os efeitos da violência, enquanto diferenças de raça maximizam esses efeitos.

No Quadro 1 tem-se uma síntese dos estudos discutidos nessa seção.

Quadro 1 – Síntese dos trabalhos empíricos sobre os determinantes do desempenho escolar

Autores/Ano	Abrangência	Método	Principais Resultados*
Coleman et. al (1966)	Estados Unidos	Modelo “ <i>input-output</i> ” e regressão linear múltipla	Elementos socioeconômicos e familiares (+)
Plowden et. al (1967)	Reino Unido	Regressão múltipla	Atitude dos pais (+)
Jencks et. al (1972)	Estados Unidos	Regressão múltipla: análise de caminho	Características familiares (+)
Rutter et. al (1979)	Londres	Regressão log-linear	Características Escolares: idade do prédio, recursos, tamanho etc. (+)
Soares et. al (2004)	Brasil	Regressão linear múltipla	Fator Escola (+)
Alves et. al (2007)	Goiás	Análise combinatória e correlações	Número de alunos por sala (-)
Laros et. al (2007)	Brasil	Regressão multinível	Nível escolar: recursos culturais (+), atraso escolar (-); Nível socioeconômico (+)
Siqueira et. al (2010)	Brasil	Probit ordenado	Escola particular (+); Sexo masculino (+); Cor branca (+); Escolaridade dos pais (+); Biblioteca (+); Quadra esportiva (+); Laboratório de ciência (+)
Ferreira et. al (2013)	Brasil	Probit	Violência (-)

Fonte: Elaboração própria.

Nota: *As variáveis com sinal positivo (+) apresentaram impacto positivo no desempenho escolar dos alunos, conforme definido pelos autores. De forma análoga, as variáveis com sinal negativo (-) apresentaram impacto negativo.

De maneira geral, o Quadro 1 apresenta a evolução da pesquisa em desempenho escolar ao longo do tempo. Podemos concluir que existem evidências suficientes para considerarmos que, tanto fatores familiares e socioeconômicos, quanto fatores intraescolares têm efeito sobre o desempenho escolar.

2.3 Estudos empíricos acerca dos Impactos da Pandemia no Desempenho Escolar

A literatura sobre os impactos da pandemia no desempenho escolar ainda é incipiente. A maioria das publicações brasileiras tem carácter bibliográfico ou se baseia em estudos de caso.

Nessa seção, são apresentados alguns trabalhos que analisaram o ensino digital e, na sequência, são apresentados trabalhos que focaram exclusivamente na análise do período pandêmico.

No âmbito do ensino remoto, Heppen et al. (2016) compara alunos reprovados em matemática no nono ano em Chicago, que participaram de atividades durante as férias para efeito de recuperação. Uma parte dos alunos participou de atividades remotas, e outra de atividades presenciais, sendo a definição aleatória. Os resultados dos alunos que realizaram atividades remotas foram piores, e, esses alunos avaliaram o curso como mais difícil do que os alunos que realizaram atividades presenciais.

Os autores ressaltam que, os resultados não devem ser generalizados pois, os alunos da amostra tinham características específicas, como, desempenho ruim em matemática.

Bettinger et. al (2023) desenvolveram e implementaram um estudo clínico randomizado controlado – *randomized control trial (RCT)* – que envolveu 6.000 alunos da terceira série de duas regiões da Rússia. Nesse estudo, a amostra foi dividida em três grupos, com diferenças no tempo de aulas por computador, sendo um grupo com 45 minutos por semana, outro grupo com duas doses de 90 minutos por semana, e um grupo de controle sem aulas por computador. Os resultados indicaram as aulas por computador tendo impacto positivo na educação, mas seus retornos são decrescentes à medida que se substitui aulas tradicionais por aulas por computador, sugerindo que uma abordagem mista de aulas tradicionais com aulas por computador seria o ideal.

Na Alemanha, uma pesquisa feita com os pais de alguns alunos mostrou que o tempo gasto em atividades escolares diminuiu pela metade durante o fechamento das escolas, saindo de 7,4 horas para 3,6 horas. Em contraste, o tempo gasto com TV, jogos de computador e celulares aumentou para 5,2 horas. (Woessmann et al., 2020).

Na literatura internacional, existe uma maior quantidade de trabalhos empíricos que visam quantificar possíveis perdas de aprendizado, relacionadas ao fechamento das escolas em diversos países.

Azevedo et al. (2021) simularam os efeitos da pandemia na proficiência dos alunos mundialmente, com os dados do Programa Internacional de Avaliação de Estudantes (PISA). Os autores consideraram quatro cenários na simulação, que variaram em relação ao tempo do fechamento das escolas e a efetividade de medidas governamentais de mitigação. O método desenvolvido foi uma ferramenta de simulação que levou em conta dados do Índice de Capital Humano, pesquisas domésticas harmonizadas do “*Global Monitoring Database*”, e a publicação “*World Economic Outlook*” do Fundo Monetário Internacional

Os resultados dos autores indicaram que, o aluno médio global poderia perder até 27 pontos no PISA, considerando o cenário pessimista.

Engzell, Frey e Verhagen (2021) estimaram o efeito do fechamento das escolas primárias da Holanda, no desempenho dos alunos. Os pesquisadores utilizaram os resultados de exames nacionais antes e depois do *lockdown*, e, compararam o progresso durante esse período, com o mesmo período nos últimos três anos. O método aplicado é análise de estatística descritiva, de forma que, os autores acessaram os resultados de testes padronizados em matemática, ortografia, leitura e uma pontuação composta pelos três assuntos de alunos de 8 a 11 anos, e transformaram esses resultados em percentil, impondo uma distribuição uniforme separadamente por disciplina, nota e ocasião do teste – meio ou fim do ano.

Os resultados dessa análise mostraram que, mesmo a Holanda tendo um *lockdown* relativamente curto – 8 semanas – e, possuir a maior taxa de acesso à banda larga do mundo, as escolas estudadas tiveram uma perda de aprendizado de, aproximadamente, 3 pontos percentuais, ou 0,08 desvio-padrão. Isso representaria um quinto de um ano letivo, que é o mesmo tempo que as escolas ficaram fechadas. Os autores, ainda, reportaram perdas 60% maiores entre alunos de casas com menos anos de escolaridade. As conclusões foram que, os alunos tiveram pouco ou nenhum progresso estudando em casa, e, que perdas maiores devem ter ocorrido em países com piores infraestruturas.

O estudo de Maldonado e De Witte (2020) reuniu dados de testes padronizados do sexto ano de escolas na Bélgica nos anos de 2015 a 2020, e desenvolveu uma regressão em painel no nível escolar. O impacto do fechamento das escolas foi medido por uma *dummy* do ano de 2020. Os autores realizam três estimações aumentando o horizonte de tempo. A primeira e mais relevante diz respeito aos anos de 2019 e 2020 apenas, e foi representada pela seguinte equação:

$$y_{i,j} = \alpha_j + \beta_j COVID19 + \delta_j X_i + \varepsilon_{i,j} \quad (2)$$

Onde $y_{i,j}$ representa a pontuação média no teste no tema j (matemática, alemão, ciências, ciências sociais e francês) no nível da escola i , que é regredido pela *dummy* COVID19, que representa o ano de 2020, assim como um vetor X_i de características da escola. São utilizados erros-padrões robustos e $\varepsilon_{i,j}$ representa os resíduos. Dessa forma, β_j identifica os efeitos do fechamento das escolas devido a pandemia em 2020 relativo a 2019.

Os resultados indicaram que, turma de 2020 teve resultados em matemática que foram 0,17 desvio-padrão abaixo que a turma anterior, enquanto, em alemão e francês as perdas foram

de 0,19 e 0,18 desvio-padrão, respectivamente. As perdas em ciências e ciências sociais não foram estatisticamente significativas.

As demais estimativas que levaram em conta um maior horizonte de tempo, modificaram a equação (2), adicionando um elemento de efeitos fixos. Os resultados foram estatisticamente significativos para perdas em matemática e alemão considerando 2017-2020 e 2015-2020.

O estudo de Yarrow, Masood e Afkar (2020) detectou que alunos da Indonésia, perderam 11 pontos na escala de leitura PISA, devido ao fechamento de quatro meses das escolas, ao mesmo passo, que. Esse trabalho utilizou a mesma metodologia do de Azevedo *et al.* (2020) citado acima, mas com um avanço na ferramenta de simulação, que permite a possibilidade de escolas estarem parcialmente ou totalmente fechadas.

Ardington, Wills e Kotze (2021) estimaram, a partir de um modelo diff-in-diff, que, alunos da quarta série da África do Sul obtiveram perdas entre 57% e 81% de um ano letivo

No âmbito nacional dos impactos da pandemia, Marcia Vieira *et al.* (2020), em sua revisão sistemática de literatura, fez um compilado dos achados, e, concluiu que, o ensino remoto teve seus principais problemas relacionados às condições financeiras e desigualdades na obtenção de materiais como celulares e computadores, na necessidade de reinvenção do docente, e dificuldade de adaptação.

No artigo “#FIQUEEMCASA: Educação na Pandemia da Covid-19”, Couto *et al.* (2020) realizaram uma pesquisa bibliográfica com amparo em reportagens nacionais e internacionais, e concluíram que, as experiências da educação online alcançaram uma parcela restrita da população, e, destaca a dificuldade para pessoas em vulnerabilidade social e exclusão digital.

Amorim, Có e Finardi (2021) aplicaram um questionário online e uma roda de conversa virtual para desenvolver o artigo “Percepções de Alunos sobre o Impacto da Pandemia na Educação: Foco no Aprendizado de Inglês”, e chegaram à conclusão de que a pandemia causou alguns efeitos positivos na educação, como práticas mais autônomas e flexíveis, mas também agravou problemas já existentes devido a uma transição para aulas virtuais sem o devido preparo. Na experiência dos alunos entrevistados, esses problemas se refletiram em questões como estresse por exposição virtual, falta de concentração e motivação.

Lichand *et al.* (2022) estudaram a perda de aprendizado na pandemia especificamente para o estado de São Paulo, com dados de testes padronizados, notas no boletim e presença dos alunos, fornecidos pela Secretária de Educação.

O método usado foi um *diff-in-diff* considerando a variação no risco de abandono e nas notas dos testes padronizados entre o primeiro e o quarto trimestre de 2020 relativo a 2019. As estimações foram feitas por mínimos quadrados ordinários, absorvendo efeitos fixos das turmas.

Para refinar o modelo, os autores, ainda, combinaram as características dos alunos (cor, gênero, notas no boletim, frequência, renda) entre os anos, estimando um *propensity score* dentro das turmas e trimestres.

Os resultados das estimações indicaram perda severa de aprendizado para os alunos que ainda estavam na escola quando as aulas presenciais retornaram – aproximadamente 75% de perda em relação a aulas presenciais. Também foi detectado grande aumento no risco de abandono.

No Quadro 2 está disposta uma síntese dos estudos apresentados nessa seção.

Quadro 2 – Síntese dos Trabalhos que analisaram os Impactos da Pandemia na Educação

Autores/Ano	Abrangência	Método	Principais Resultados
Azevedo et. al (2021)	Mundial	Simulação	Possível perda de até 27 pontos no PISA
Verhagen et. al (2021)	Holanda	Estatística descritiva	Perda de aprendizado de 3 pontos percentuais
De Witte et. al (2022)	Bélgica	Regressão em painel	Perda de aprendizado em matemática e alemão
Afkar et. al (2020)	Indonésia	Simulação	Perda de 11 pontos no PISA
Kotze et. al (2021)	África do Sul	Modelo diff-in-diff	Perdas entre 57% e 81% de um ano letivo
Couto et. al (2020)	Brasil	Pesquisa bibliográfica	Dificuldade para pessoas em vulnerabilidade social
Lichand et. al (2022)	São Paulo	Modelo diff-in-diff	Perda de 75% em relação às aulas presenciais

Fonte: Elaboração própria.

O Quadro 2 demonstra que, perda de aprendizado relacionada ao fechamento das escolas está sendo observada globalmente, tanto em países mais ricos e desenvolvidos quanto em países subdesenvolvidos.

3 METODOLOGIA


Essa seção apresenta os aspectos metodológicos aplicados nessa pesquisa, bem como, a base de dados.

3.1 Base de Dados

Os dados utilizados são do Sistema de Avaliação da Educação Básica (SAEB), que consiste em um conjunto de avaliações organizadas pelo Inep, para fins de diagnóstico da educação básica brasileira.

O SAEB é realizado a cada dois anos em todas as escolas da rede pública e, em amostra da rede privada para os alunos do 5º e 9º ano do Ensino Fundamental, e 3º ano do Ensino Médio. Os alunos realizam testes de português e matemática. A Figura 2 demonstra um exemplo de questões para o 5º ano do Ensino Fundamental.

Figura 1 – Exemplo de questão dos testes de língua portuguesa (a) e matemática (b) para o 5º ano do Ensino Fundamental

(a)	(b)
SUPEREXPERIÊNCIAS Alô, Galera da CHC! Eu sou o Thiago. Já escrevi algumas vezes, inclusive, minha carta foi publicada na CHC 82. Todo ano na minha cidade acontece a Feira de Ciências, Arte e Tecnologia (Feciart). Apresentei uma experiência que vocês publicaram e fui classificado entre as superexperiências. Gostaria que vocês me enviassem outra experiência interessante. Quem sabe não ganho o prêmio regional da Feciart? <i>Ciências Hoje das Crianças</i>, n. 102, maio 2000. No trecho "Alô, Galera da CHC!", a expressão destacada demonstra uma linguagem normalmente usada por (A) advogados. (B) cientistas. (C) estudantes. (D) médicos.	A imagem representa uma estante com filmes da coleção de Roberta:  Roberta está em frente da estante e escolhe o terceiro filme, da esquerda para direita, na segunda prateleira. Qual foi o filme escolhido? (A) A Era do Gelo 1 (B) A Professora Maluquinha (C) A Bela e a Fera (D) O Rei Leão 1

Fonte: Daeb/Inep, Banco Nacional de Itens, 2017.

Além dos testes cognitivos para avaliar a aprendizagem, o SAEB aplica questionários para os alunos, professores e diretores, que abordam temas como nível socioeconômico, infraestrutura, formação dos professores, programas estruturados, entre outros tópicos.

Dessa forma, os dados do SAEB apresentam uma variável de resultado – pontuação nos testes cognitivos – e, os questionários levantam diversas variáveis de controle, tornando esses dados ideais para análise proposta.

O objetivo da pesquisa é analisar o efeito da transição para o ensino remoto, imposta pela pandemia da COVID-19, no aprendizado dos estudantes brasileiros de escolas públicas. Além disso, busca-se compreender como as desigualdades prévias no sistema educacional podem ter modulado os efeitos dessa transição, afetando de maneira desigual a qualidade e a efetividade do ensino remoto entre diferentes grupos de alunos. Para isso, foram comparados o grupo de alunos que realizou a prova SAEB anos finais – 9º ano do Ensino Fundamental – um ano antes do ensino remoto (2019), com o grupo de alunos que realizou a prova SAEB anos finais, um ano depois do ensino remoto (2021). Espera-se encontrar evidências de que o grupo de alunos que fez a prova depois da pandemia teve um déficit de aprendizado.

Os dados do SAEB de 2019 e 2021 contém informações sobre mais de 2 milhões de alunos brasileiros no 9º ano – 2.388.931 e 2.591.937 respectivamente. Esses dados foram filtrados, a fim de limpar as observações que não tiverem todas as informações, no caso, os alunos que não tiverem respondido o questionário ou respondido de maneira incompleta.

O ideal seria acompanhar os resultados do mesmo aluno, antes e depois do ensino remoto, porém, os dados abertos do SAEB têm caráter anônimo, no sentido de que um mesmo aluno não pode ser identificado mesmo que ele tenha feito a prova duas vezes (no quinto e no nono ano, respectivamente). Ao mesmo tempo, comparar os alunos de 2019 e 2021 apenas sobre a assunção de que esses são similares, poderia acarretar viés de seleção, que é um termo estatístico para definir diferenças sistemáticas entre os indivíduos analisados. Para contornar esse problema, será utilizado o método *propensity score matching* (PSM).

3.2 *Propensity Score Matching* (PSM)

O PSM é uma técnica estatística, onde um grupo de tratamento é comparado com um ou mais grupos de controle. Essa técnica foi introduzida na literatura por Paul Rosenbaum e Donald Rubin em 1983. Ela atribui uma probabilidade condicional de receber o tratamento a

cada indivíduo da amostra, controlando suas características. Essa probabilidade é chamada *propensity score*, e é calculada a partir de uma regressão logística (logit).

Após calculada a probabilidade, é feito o processo de *matching*, onde indivíduos do grupo de tratamento são pareados com indivíduos do grupo de controle que apresentam probabilidades similares.

De acordo com Rosenbaum e Rubin (1983), o *propensity score* para o indivíduo i ($i = 1, \dots, N$), é a probabilidade condicional de receber um tratamento ($W_i = 1$) versus não receber o tratamento ($W_i = 0$), dado um vetor de covariáveis observadas, x_i . Formalmente:

$$e(x_i) = pr(W_i = 1 | X_i = x_i) \quad (3)$$

O PSM é muito utilizado para análise de políticas públicas. Nesse estudo, o impacto do ensino remoto no aprendizado dos alunos foi estimado, baseado na comparação de unidades de análise i (nesse caso, alunos do 9º ano do Ensino Fundamental) afetadas pelo ensino remoto *versus* não afetadas. A diferença obtida na variável de interesse consiste no impacto do ensino remoto. Ou seja:

$$\delta_i = \gamma_{1i} - \gamma_{0i} \quad (4)$$

Em que, δ_i é o efeito do ensino remoto na variável de interesse (nota na Prova SAEB), em relação a unidade de análise (alunos do 9º ano) i ; γ_{1i} é o valor da variável de interesse para alunos i impactados pelo ensino remoto; e γ_{0i} é o valor da variável de interesse para alunos i não impactados pelo ensino remoto.

Para efeito desse estudo, o grupo de tratamento são os alunos que realizaram a prova SAEB em 2021, após o ensino remoto, e o grupo de controle serão os alunos que realizaram a prova SAEB em 2019, antes do ensino remoto. Deseja-se combinar alunos que tenham características semelhantes entre os anos.

Após uma verificação completa dos questionários aplicados em ambos os anos, foram selecionadas as seguintes questões referentes aos alunos do 9º ano do Ensino Fundamental, para ferramenta de análise:

Quadro 3 – Questões selecionadas para análise: Questionário dos Alunos do 9º ano

Código no questionário		Descrição
2019	2021	
ID_SAEB	ID_SAEB	Ano de aplicação do SAEB
ID_REGIAO	ID_REGIAO	Código da Região
ID_AREA	ID_AREA	Capital ou Interior
ID_ESCOLA	ID_ESCOLA	Código da Escola
IN_PUBLICA	IN_PUBLICA	Indica se a escola é pública ou não
ID_LOCALIZACAO	ID_LOCALIZACAO	Urbana ou Rural
PROFICIENCIA_LP_SAEB	PROFICIENCIA_LP_SAEB	Proficiência do aluno em Língua Portuguesa
PROFICIENCIA_MT_SAEB	PROFICIENCIA_MT_SAEB	Proficiência do aluno em Matemática
TX_RESP_Q002	TX_RESP_Q04	Qual é a sua cor ou raça?
TX_RESP_Q004	TX_RESP_Q07	Qual a maior escolaridade da sua mãe (ou mulher responsável por você)?
TX_RESP_Q005	TX_RESP_Q08	Qual a maior escolaridade do seu pai (ou homem responsável por você)?
TX_RESP_Q006B	TX_RESP_Q09c	Com que frequência seus pais ou responsáveis costumam incentivar você a estudar?
TX_RESP_Q006C	TX_RESP_Q09f	Com que frequência seus pais ou responsáveis costumam ir às reuniões de pais na escola?
TX_RESP_Q008A	TX_RESP_Q10a	Na rua em que você mora tem asfalto ou calçamento?
TX_RESP_Q008B	TX_RESP_Q10b	Na rua em que você mora tem água tratada?
TX_RESP_Q008C	TX_RESP_Q10c	Na rua em que você mora tem iluminação?
TX_RESP_Q010B	TX_RESP_Q12b	Na sua casa tem: Rede Wi-Fi?
TX_RESP_Q015	TX_RESP_Q18	Você já foi reprovado?

Fonte: Elaboração própria.

A partir dessas questões foram criadas as seguintes variáveis para serem usadas como covariadas ou características pré-definidas para o pareamento (variáveis explicativas do modelo logit):

Quadro 4 – Variáveis Explicativas do Modelo Logit: Características de Pareamento

Abreviatura	Significado
Dcor	Dummy de cor ou raça. 1 para brancos e amarelos; 0 para pretos, pardos e indígenas.
Desclmae	Dummy de escolaridade da mãe. 1 para Ensino Fundamental completo; 0 para incompleto
Desclpai	Dummy de escolaridade do pai. 1 para Ensino Fundamental completo; 0 para incompleto
Dincentivo	Dummy de incentivo ao estudo por parte dos pais. 1 para sempre ou quase sempre; 0 para nunca, quase nunca ou de vez em quando
Dreuniao	Dummy de comparecimento dos pais em reuniões escolares. 1 para sempre ou quase sempre; 0 para nunca, quase nunca ou de vez em quando
Dasfalto	Dummy de asfalto ou calçamento na rua de moradia. 1 para sim; 0 para não
Dagua	Dummy de água potável em casa. 1 para sim; 0 para não
Diluminacao	Dummy de iluminação na rua de moradia. 1 para sim; 0 para não
Dwifi	Dummy de presença de Wi-Fi em casa. 1 para sim; 0 para não
Dreprovacao	Dummy de reprovacao. 1 se nunca reprovou; 0 se já reprovou.
Dregiao*	Dummy de região. 1 para Norte e Nordeste; 0 para Sul, Sudeste e Centro-Oeste.
Darea	Dummy de capital. 1 se a escola for em capital; 0 se for no interior.
Dlocalizacao	Dummy de localização. 1 se for urbana; 0 se for rural
ICH	Índice de Capital Humano das Escolas**
IRF	Índice de Recursos Financeiros das Escolas**

Fonte: Elaboração própria

Nota: (*) Para definição da Dummy de região foram reunidas as regiões Norte e Nordeste pela concepção da literatura de que estas poderiam estar atrasadas, em termos de aprendizagem acumulada, em relação as demais regiões. (Para mais detalhes, observar a Figura 4 na seção 4). (**) na sequência, é apresentado como foi calculado esse índice.

Essas características estão em linha com grande parte da pesquisa em determinantes do desempenho escolar, de modo que os fatores sociais e familiares, apresentam grande influência, assim como a dimensão do aluno e da escola. (Coleman *et al.*, 1966; Hanushek, 1970; Brookover, 1978; Rutter *et al.*, 1979; Alves; Soares, 2007; Brooke; Soares, 2008).

A questão de indicador de escola pública foi utilizada na filtragem dos dados, a fim de que, mantivesse na amostra apenas os alunos de escola pública, descartando os alunos de escolas particulares. Essa decisão foi tomada baseada na óbvia diferença estrutural e econômica entre escolas públicas e privadas, e, na diferença entre os alunos dessas escolas. Além disso, a Prova SAEB é aplicada na totalidade das escolas públicas que tenham, pelo menos, 10 alunos matriculados, enquanto apenas algumas escolas privadas são convidadas em caráter amostral.

Ainda retirando as escolas privadas da amostra, existem diferenças estruturais entre as próprias escolas públicas, e, como a literatura mostra que o fator escola tem impacto no desempenho dos alunos, foram construídos dois índices escolares, os quais foram incluídos, também, como covariadas do modelo logit.

Para construção desses índices, foram utilizados os questionários dos diretores aplicados pelo SAEB. As questões selecionadas foram as seguintes:

Quadro 5 – Questões selecionadas para análise: Questionário dos diretores

Código da Questão		Abreviatura	Descrição
2019	2021		
ID_SAEB	ID_SAEB	ID_SAEB	Ano de aplicação do SAEB
ID_ESCOLA	ID_ESCOLA	ID_ESCOLA	Código da Escola
TX_RESP_Q041	TX_RESP_043	A1	Os recursos financeiros foram suficientes?
TX_RESP_Q042	TX_RESP_044	B1	O quadro de professores estava completo?
TX_RESP_Q043	TX_RESP_045	B2	Havia quantidade suficiente de pessoal administrativo?
TX_RESP_Q044	TX_RESP_046	B3	Havia quantidade suficiente de pessoal para apoio pedagógico (coordenador, orientador etc.)?
TX_RESP_Q045	TX_RESP_047	A2	Os recursos pedagógicos foram suficientes?
TX_RESP_Q047	TX_RESP_049	B4	Os (As) professores (as) foram assíduos (as)?
TX_RESP_Q049	TX_RESP_050	B5	As substituições das ausências de professores (as) foram facilmente realizadas?
TX_RESP_Q056	TX_RESP_Q056	A3	Todos os (as) alunos (as) receberam livros didáticos?

Fonte: Elaboração própria.

Todas as questões poderiam ser respondidas entre quatro opções (a, b, c ou d) em ordem crescente de concordância, ou seja, caso o diretor assinalasse a alternativa a, ele discorda fortemente; caso assinalasse b, discorda; c, concorda; e d, concorda fortemente.

A partir disso, foram construídos um índice de Capital Humano (ICH) e um índice de Recursos Financeiros (IRF) para cada escola pública cujo diretor respondeu o questionário em ambos os anos. O critério para construção desses índices consistiu na atribuição de pontos em ordem crescente de concordância com as questões, somatório desses pontos e divisão pelo número de questões. O quadro 6 demonstra a pontuação atribuída para as respostas dos diretores.

Quadro 6 – Pontuações atribuídas para cada resposta do diretor

Resposta	Pontuação atribuída
A) Discordo fortemente	0
B) Discordo	0,2
C) Concordo	0,8
D) Concordo fortemente	1

Fonte: Elaboração própria.

O Índice de Capital Humano (ICH) foi construído a partir das respostas para as questões B1, B2, B3, B4 e B5 do Quadro 5. Para cada questão foi atribuída a pontuação designada pelo Quadro 6, de forma que:

$$ICH = \frac{B1 + B2 + B3 + B4 + B5}{5} \quad (5)$$

De modo semelhante, o Índice de Recursos Financeiros (IRF) da escola foi construído baseado nas questões A1, A2 e A3. Sendo assim:

$$IRF = \frac{A1 + A2 + A3}{3} \quad (6)$$

O modelo logit é estimado com base nas covariadas definidas (Quadro 4), e o processo de *matching* é feito baseado no pressuposto de independência condicional. Temos:

$$P(T_i = 1|X_i) = \frac{1}{1 + e^{-x_i'\beta}} \quad (7)$$

Onde $P(T_i = 1|X_i)$ representa a probabilidade do aluno ser afetado pelo ensino remoto baseado nas suas covariadas.

Após ter calculado um *score de propensão* – por meio do modelo logit – para cada aluno (tanto de tratamento – alunos que realizaram a prova em 2021 – como também para o grupo de controle – alunos de 2019), realiza-se o pareamento dos alunos com escores idênticos ou próximos por meio de algum algoritmo de vizinhança.

Com as treze *dummies* do Quadro 4, e os dois índices criados, a análise conta com quinze variáveis explicativas do modelo logit. A variável dependente é uma *dummy* de ano (1 para o ano após o ensino remoto, 0 caso contrário), denominada DMANO. Formalmente, o logit estimado para obter o *score de propensão* foi:

$$\begin{aligned} dmano = & dcor + desclmae + desclpai + dincentivo + dreuniao \\ & + dasfalto + dagua + diluminacao + dwifi + dreprovacao \\ & + dregiao + darea + dlocalizacao + ICH + IRF \end{aligned} \quad (8)$$

Para o pareamento, é possível utilizar algumas diferentes técnicas de correspondência. Nessa dissertação, foram testadas as técnicas de *Nearest Neighbor* (vizinho mais próximo) e *Caliper*.

Na correspondência por *Nearest Neighbor*, cada unidade de tratamento é combinada com uma unidade de comparação com o score de propensão mais próximo. Já na correspondência por *Caliper*, se escolhe um limite de tolerância na distância máxima entre os scores de propensão das unidades. (Cavalcanti, 2015).

Os dados foram compilados, agrupados e filtrados pelo *software* RStudio, da linguagem R. Dessa forma, anterior à estimação do *propensity score* foram retirados da amostra os alunos que não tinham respostas completas para as questões selecionadas. Ademais, foram retirados da amostra os alunos que responderam “não quero declarar” para a questão “Qual sua cor ou raça?”, assim como, os alunos que responderam “não sei” para as questões de escolaridade do pai, mãe ou responsáveis.

Após essa filtragem inicial, a amostra completa contava com 770.981 observações para 2021, e 816.188 observações para 2019. Em seguida, foi realizado o agrupamento, totalizando 1.587.169 observações. Para atribuição dos índices de escola para cada aluno, foi utilizada a variável de identificação “ID_ESCOLA”, disponível nos questionários de alunos e diretores. Por fim, foram retirados da amostra os alunos cujos diretores de suas escolas apresentaram respostas incompletas nas questões selecionadas para construção dos índices. A amostra final ficou com 1.473.585 observações.

Nesse banco de dados final foi aplicado o modelo logit da equação (7), e realizado o pareamento através do pacote “MatchIt”. Foram testadas as técnicas de pareamento *Nearest Neighbor*, e *caliper* de 0,1 e 0,2. O melhor algoritmo de vizinhança que juntou tratados e controle foi o *caliper* de 0,1. Os gráficos de balanceamento dos algoritmos estimados estão disponíveis no Apêndice.

Posteriormente ao pareamento, os alunos com escores de propensão semelhantes foram agrupados para comparação. Em seguida, foram analisados os resultados da prova SAEB de português e matemática entre o grupo de tratamento (alunos de 2021) e o grupo de controle (alunos de 2019). Isso permite verificar se há diferenças estatisticamente significativas nos níveis de aprendizagem entre os dois grupos, considerando os fatores controlados pelo pareamento.

Além de estimar médios para o grupo de tratados versus o grupo de controle, foram estimados outros modelos considerando os tratados e controles conforme apresentado no Quadro 7, para efeito de robustez e, também, com o objetivo de compreender como as

desigualdades prévias no sistema educacional podem ter modulado os efeitos dessa transição, afetando de maneira desigual a qualidade e efetividade do ensino remoto entre diferentes grupos de alunos.

Para isso, foram estimados PMS adicionais relacionado à escolaridade dos pais entre os dois anos (2021 continuou a ser o ano de tratamento e 2019, de controle), de forma a observar alunos que tenham a maior escolaridade entre os pais, ou seja, ensino superior completo, e, alunos que tenham a menor escolaridade entre os pais, ou seja, 5º ano do Ensino Fundamental incompleto. Essas estimações foram efetivadas com o propósito de analisar se as diferenças na condição socioeconômica apresentam resultado em diferenças de aprendizado após o ensino remoto. Ressalta-se que alguns estudos (PNAD, 2014; Smeeding, 2006) evidenciam que quanto maior for a escolaridade dos pais, maior tende a ser a renda familiar².

Além disso, as desigualdades entre as escolas também foram consideradas. Para isso, os alunos foram classificados conforme o Índice de Recursos Financeiros (IRF) de 2021. Na primeira estimativa, foram selecionados apenas os estudantes com menor IRF em 2021 (primeiro quartil – grupo de tratamento) e comparados com os alunos do primeiro quartil do IRF de 2019. Em seguida, foram selecionados apenas os alunos do quarto quartil de 2021 (grupo de tratamento) e comparados com os estudantes do quarto quartil de 2019 (grupo de controle). O mesmo procedimento foi efetivado para o ICH.

Quadro 7: Grupo de Tratamento e Controle – Modelos PSM – Variável de efeito: Prova SAEB

Modelo	Tratados	Controles
i.	Alunos 9º ano 2021	Alunos 9º ano 2019
ii.	Alunos 9º ano de 2021, e que, ambos os pais tinham ensino superior completo	Alunos 9º ano de 2019, e que, ambos os pais tinham ensino superior completo
iii.	Alunos 9º ano de 2021, e que, pelo menos um dos pais tinham ensino superior completo.	Alunos 9º ano de 2019, e que, pelo menos um dos pais tinham ensino superior completo.
iv.	Alunos 9º ano de 2021, e que, pelo menos um dos pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)	Alunos 9º ano de 2021, e que, pelo menos um dos pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)

² O ideal seria incluir uma variável de renda familiar, mas essa informação não estava disponível, portanto, optou-se por utilizar a escolaridade dos pais como *proxy* de nível econômico familiar. De acordo com Soares e Mendonça (2003) e Jesus e Laros (2004), o nível socioeconômico de um aluno pode ser medido pela escolaridade dos pais, presença ou ausência de determinados itens em casa e outros fatores. O próprio Inep utiliza esses fatores no cálculo de seu índice socioeconômico.

v.	Alunos 9º de 2021, e que, ambos os pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)	Alunos 9º ano de 2019, e que, ambos os pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)
vi.	Primeiro quartil do IRF de 2021	Primeiro quartil do IRF de 2019
vii.	Quarto quartil do IRF de 2021	Quarto quartil do IRF de 2019
viii.	Primeiro quartil do ICH de 2021	Primeiro quartil do ICH de 2019
ix.	Quarto quartil do ICH de 2021	Quarto quartil do ICH de 2019

Fonte: Elaboração própria.

Na estimação do modelo de robustez (ii. a ix.) foram criadas bases de dados específicas para cada ocasião. O número de observações em cada amostra está disponível no Quadro 8:

Quadro 8: Tamanho da amostra de cada modelo estimado

Modelo	Amostra	
	Tratamento	Controle
ii.	56.004	55.896
iii.	194.691	200.661
iv.	145.641	168.135
v.	40.239	47.257
vi.	208.483	210.358
vii.	119.185	156.459
viii.	178.920	208.984
ix.	80.986	185.847

Fonte: Elaboração própria

Para essas estimações, foi rodado o mesmo modelo logit da equação (7), porém para os modelos de ii. a v. foram retiradas as variáveis “*descmae*” e “*desclpai*”, e para os modelos de vi. a ix. foram retirados os índices usados na distribuição dos quartis.


Cada uma dessas estimações, foram testadas com os mesmos algoritmos de pareamento apresentados *a priori*, e escolhido aquele que melhor se ajustava aos dados. Todos os modelos mostraram maior eficiência no pareamento de *caliper* 0,1. Os gráficos de balanceamento pós-pareamento que guiaram essa decisão estão disponíveis no Apêndice A.

4 COVID-19 E DESEMPENHO ESCOLAR DOS ESTUDANTES BRASILEIROS: ANÁLISE EMPÍRICA

Conforme discutido na Seção 1, a educação formal desempenha um papel fundamental na formação do capital humano. Em particular, a qualidade da educação é determinante no desenvolvimento regional, impactando aspectos como aumento da produtividade e a criação de novas tecnológicas. Nesse contexto, é essencial refletir sobre as possíveis perdas educacionais no Brasil durante o período de ensino remoto, especialmente considerando suas dimensões continentais e significativa heterogeneidade regional. Assim, torna-se necessário não apenas analisar os efeitos do ensino remoto em nível nacional, mas também compreender suas repercussões específicas em cada região.

Na Figura 2 está representada a evolução da média nacional na Prova SAEB do 9º ano do Ensino Fundamental nas escolas públicas, de 2005 a 2021, discriminado em português, matemática e nota padronizada.

Figura 2 – Evolução da Média Nacional dos alunos do 9º ano de escolas públicas na Prova SAEB – Brasil: 2005 - 2021



Fonte: INEP, 2024

A escolha desse período – visto que a Prova SAEB acontece desde 1990 – é explicada pelo fato de que, em 2005, houve uma reestruturação no sistema da avaliação. A Portaria MEC – nº 931, de março de 2005, estabeleceu que o SAEB passaria a ser composto por duas avaliações: a Avaliação Nacional da Educação Básica (ANEB) e pela Avaliação Nacional do

Rendimento Educacional (Anresc), que ficou popularmente conhecida como Prova Brasil (da Silva *et. al.*, 2022).

Essa mudança foi significativa, principalmente, no âmbito da Prova Brasil (Anresc) que passou a ter caráter censitário, em detrimento de amostral, de forma que, todas as escolas públicas do país, que tivessem ao menos 30 alunos matriculados no 5º ano e/ou 9º ano seriam testadas, gerando resultados por escolas. Logo em sequência, em 2007 é criado o Índice de Desenvolvimento da Educação Básica (IDEB), que levava em conta o desempenho dos alunos medido pelo SAEB, e taxas de aprovação, reprovação e abandono medidas pelo Censo Escolar.

Analisando as evoluções (Figura 2), tem-se clara tendência de crescimento da média nacional, principalmente no quadriênio de 2005-2009 e 2013-2017, saindo de uma nota média padronizada de 4,52 em 2005, chegando a 5,36 em 2017.


É possível que esse aumento seja, parcialmente, explicado pela mudança na estrutura da prova, de modo que, ao aumentar a abrangência e passar a medir notas e IDEB de cada escola, tenha acontecido um incentivo a melhoria educacional.

No ano de 2013, ocorreu uma queda na média de matemática, e consequentemente, na nota padronizada. A explicação para esse movimento não é evidente nem discutida a contento na literatura da área. No entanto, na edição de 2013, houve uma inclusão experimental de uma prova de ciências para os alunos do 9º ano, em parte das escolas. Essa poderia ser uma das explicações para a queda da média em matemática, no sentido de que, haveria mais uma avaliação para o aluno completar.

Observa-se uma interrupção na tendência de 2019 para 2021, indicando uma perda significativa de aprendizagem no Brasil durante o ensino remoto na pandemia, com uma queda ainda mais acentuada na área de matemática, onde houve um retrocesso médio de 2,478%. Em português, o retrocesso médio foi de 0,72%.

No entanto, é relevante questionar se essa tendência se repetiu em todos os municípios brasileiros, dado que, antes da pandemia, havia uma heterogeneidade na distribuição da aprendizagem, com uma concentração do conhecimento em partes específicas do território, conforme pode ser verificado nas Figuras 3a, 3c e 3e.

Figura 3 – Nota Média da Prova SAEB de Matemática e de Português: Municípios Brasileiros em 2019 e 2021




Fonte: Elaboração própria baseado em dados do INEP.

Com efeito, as maiores médias da prova SAEB estavam concentradas especialmente nas regiões Sul e Sudeste, corroborando com as evidências de Cavalcanti *et al.* (2021).

Ademais, ao comparar os anos de 2019 e 2021, ratifica-se perda de aprendizagem durante a pandemia, afetando todas as regiões do Brasil. Esse impacto é evidenciado pelo clareamento dos mapas (Figura 3) ao longo do tempo, o que reflete a redução das médias da Prova Saeb, tanto em português quanto em matemática.

A nota padronizada da Prova SAEB é elaborada levando em consideração todos os âmbitos do conhecimento que foram testados na prova. Novamente, ao compararmos a média dos desempenhos das escolas públicas dos municípios, é notório a perda de tonalidade no mapa de 2021, simbolizando que a queda de aprendizagem nesse intervalo de tempo não esteve concentrada em apenas uma das matérias, mas que, pode ser entendida como uma perda generalizada. A Figura 4 reforça essa análise ao apresentar a variação no desempenho entre 2019 e 2021.

Figura 4 - Variação na Média Municipal da Prova SAEB – 2021/2019



Fonte: Elaboração própria, baseado em dados do INEP.

Um dado relevante, apontado por pesquisas anteriores (Cavalcanti *et al.*, 2020; Fujita *et al.*, 2021) e, parcialmente corroborado pela Figura 4, é que a proficiência em matemática e português parecem seguir um padrão semelhante de variação. Em outras palavras, municípios que apresentam variação negativa em uma dessas áreas também exibiram variação negativa na outra (correlação de 0,92).

Ademais, conforme pode-se observar na Figura 4, ocorre uma predominância de observações em vermelho, representando que a maioria dos municípios tiveram uma redução no desempenho das escolas públicas na Prova SAEB de 2019 para 2021. Especificamente, 61,05% dos municípios brasileiros que realizaram a prova SAEB do 9º ano apresentaram variação negativa na prova de matemática, e 60,21% na prova de português. A Tabela 1 apresenta os números completos discriminados nacionalmente e por regiões.

Tabela 1 – Variação no Desempenho da Prova SAEB por Regiões

Abrangência	Matéria da Prova	Percentual de Municípios com Variação Negativa	Percentual de Municípios com Variação Positiva	Percentual de Municípios que Mantiveram a Nota
Brasil	Matemática	61,05%	38,87%	0,09%
	Português	60,21%	39,75%	0,04%
	Nota Padronizada	67,85%	32,08%	0,06%
Região Norte	Matemática	70,23%	29,19%	0,58%
	Português	57,51%	42,20%	0,29%
	Nota Padronizada	66,47%	33,53%	0,00%
Região Nordeste	Matemática	67,57%	32,30%	0,13%
	Português	61,55%	38,45%	0,00%
	Nota Padronizada	67,04%	34,98%	0,20%
Região Centro-Oeste	Matemática	63,54%	36,46%	0,00%
	Português	63,80%	36,20%	0,00%
	Nota Padronizada	70,63%	29,37%	0,00%
Região Sudeste	Matemática	56,91%	43,09%	0,00%
	Português	56,77%	43,16%	0,07%
	Nota Padronizada	66,93%	33,00%	0,07%
Região Sul	Matemática	52,79%	47,21%	0,00%
	Português	62,61%	37,39%	0,00%
	Nota Padronizada	69,81%	30,19%	0,00%

Fonte: Elaboração própria, baseado em dados do INEP.

Nota: Para esse cálculo foram retirados os municípios que não apresentaram nota SAEB para o 9º ano em 2019 e 2021.

Percebemos nas Regiões Sul e Sudeste, uma maior resistência na queda do desempenho, mas mesmo nessas regiões a porcentagem de municípios com variação negativa superou a quantidade com variação positiva. Esses dados contribuem novamente para a concepção da literatura de que, a aprendizagem é mais concentrada nessas regiões do país.

Nas regiões Norte e Nordeste, a queda do desempenho, principalmente em matemática, foi mais acentuada, enquanto nas regiões Sul e Centro – Oeste tiveram mais municípios com queda nas notas em português.

De maneira geral, ao observarmos a variação na nota padronizada, todas as regiões do Brasil apresentaram uma porcentagem maior que 60% de municípios com variação negativa. Ao considerarmos o país como um todo, 67,85% dos municípios que tiveram nota SAEB nos dois anos em questão apresentaram variação negativa.

Tabela 2: Estatística Descritiva – Nota SAEB – Português, Matemática e Nota Padronizada – Municípios – Brasil e Regiões – 2019 e 2021

Abrangência	Nota SAEB	2019			2021		
		Média	Desvio-padrão	Coefficiente de Variação	Média	Desvio-padrão	Coefficiente de Variação
Brasil	Português	254,34	15,95	0,062	251,99	15,18	0,060
	Matemática	258,45	18,38	0,071	252,20	17,64	0,069
	Padronizada	5,21	0,56	0,107	5,06	0,53	0,105
Região Norte	Português	242,00	13,83	0,056	240,68	11,26	0,046
	Matemática	244,17	15,43	0,062	238,65	12,79	0,052
	Padronizada	4,76	0,47	0,097	4,65	0,38	0,081
Região Nordeste	Português	246,22	15,88	0,064	243,77	15,37	0,063
	Matemática	248,57	18,62	0,074	242,37	18,30	0,075
	Padronizada	4,91	0,56	0,114	4,76	0,54	0,115
Região Centro-Oeste	Português	256,25	13,12	0,053	253,51	12,28	0,050
	Matemática	259,30	14,28	0,057	253,91	13,75	0,056
	Padronizada	5,25	0,44	0,090	5,12	0,42	0,088
Região Sudeste	Português	259,30	12,91	0,052	257,51	12,07	0,049
	Matemática	264,78	14,39	0,057	258,04	13,32	0,054
	Padronizada	5,40	0,44	0,090	5,25	0,41	0,086
Região Sul	Português	263,22	13,01	0,052	259,97	12,49	0,051
	Matemática	269,12	14,44	0,058	262,90	13,86	0,057
	Padronizada	5,53	0,44	0,089	5,38	0,42	0,088

Fonte: Elaboração própria, baseado em dados do Inep.

Verificamos na Tabela 2, a queda generalizada nas médias das escolas públicas dos municípios brasileiros em todas as regiões. A observação de que, no triênio 2019-2021 nenhuma região do país teve aumento na sua média, após uma longa tendência crescente, é uma evidência clara de perda de aprendizagem durante o ensino remoto.

4.1 Efeito do Ensino Remoto na Aprendizagem dos Alunos Brasileiros

Diante de todo o exposto, a perda de aprendizagem dos alunos durante o ensino remoto torna-se evidente. Na Tabela 3, estão os resultados das estimações de todos os modelos do Quadro 7, feitas a partir do *propensity score matching*, considerando como variáveis de efeito as proficiências do aluno em matemática e português.

Tabela 3 – Efeito Médio na Proficiência em Matemática de ter estudado durante ensino remoto em alunos do 9º ano de escolas públicas

Tratado	Controle	Efeito Médio		Erro Padrão	
		Matemática	Português	Matemática	Português
Alunos 9º ano 2021	Alunos 9º ano 2019	-10,1*	-5,68*	0,09	0,09
Alunos 9º ano de 2021, e que, ambos os pais tinham ensino superior completo	Alunos 9º ano de 2019, e que, ambos os pais tinham ensino superior completo	-7,65*	-2,74*	0,355	0,357
Alunos 9º ano de 2021, e que, pelo menos um dos pais tinham ensino superior completo.	Alunos 9º ano de 2019, e que, pelo menos um dos pais tinham ensino superior completo.	-7,91*	-3,15*	0,183	0,186
Alunos 9º ano de 2021, e que, pelo menos um dos pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)	Alunos 9º ano de 2019, e que, pelo menos um dos pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)	-10,9*	-6,64*	0,209	0,211
Alunos 9º de 2021, e que, ambos os pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)	Alunos 9º ano de 2019, e que, ambos os pais tinham 5º ano do Ensino Fundamental incompleto (menor escolaridade)	-10,9*	-7,12*	0,402	0,398
Primeiro quartil do IRF de 2021	Primeiro quartil do IRF de 2019	-8,24*	-4,36*	0,159	0,163
Quarto quartil do IRF de 2021	Quarto quartil do IRF de 2019	-7,65*	-2,57*	0,189	0,191
Primeiro quartil do ICH de 2021	Primeiro quartil do ICH de 2019	-7,06*	-3,54*	0,181	0,188
Quarto quartil do ICH de 2021	Quarto quartil do ICH de 2019	-9,12*	-4,65*	0,249	0,247

Fonte: Resultado de pesquisa.

Nota: algoritmo de pareamento: caliper de 0,1

*Estatisticamente significativo a 5%.

A interpretação desses resultados passa pela análise do efeito médio de receber o tratamento. Nessa dissertação, em todos os cenários modelados, o tratamento é o estudo se dar após o ensino remoto (2021). Portanto, observando a primeira estimação, o efeito médio de ter estudado com ensino remoto na proficiência de matemática, foi de -10,1 pontos. Como os alunos foram pareados a partir do PSM, podemos dizer que alunos semelhantes baseados nas covariadas definidas, tiveram uma diferença de proficiência de dez pontos em 2021, com relação a 2019. Uma redução bastante considerável. No caso de Português, houve uma queda média de 5,68 pontos dos alunos de 2021, em relação à alunos semelhantes (com base no PSM) de 2019.

O efeito médio de receber o tratamento é negativo em todas as situações exploradas. Essa é uma evidência clara de que, a perda de aprendizagem durante o ensino remoto foi generalizada. Porém, é, também, exposto que as diferenças socioeconômicas dos alunos apresentam grande papel na suavização ou potencialização dessa perda. Se considerarmos a escolaridade dos pais como *proxy* para renda familiar, a Tabela 3 demonstra que, alunos de famílias mais pobres foram afetados de forma bem mais intensa que alunos de famílias mais ricas.

Isso pode decorrer de fatores como a infraestrutura, de maneira que, famílias com melhor condição socioeconômica podem fornecer mais recursos educacionais em casa (Souza et. al, 2018). Além disso, pais de famílias mais pobres tem maiores restrições para dar apoio ao aprendizado de seus filhos, e compensar suas perdas de aprendizagem (Pinto, 2023). Outro fator importante é o programa de alimentação das escolas (Anjos; Azoni, 2022), de modo que, o fechamento das escolas privou muitos alunos de famílias mais carentes de terem acesso a nutrição adequada fornecida pelas escolas, o que pode afetar o desenvolvimento cognitivo.

Ademais, pais de famílias mais pobres tinham menores chances de conseguirem o privilégio de trabalhar em casa, durante a pandemia (Chen et. al, 2022). Nesse sentido, esses trabalhadores estariam mais expostos ao vírus e, também, ao risco de serem demitidos. De acordo com Cabral et. al, 2024, a pandemia aumentou o desemprego, e fez com que muitos estudantes se vissem obrigados a buscar trabalho, o que dificultou ou impossibilitou que continuassem seus estudos.

Outra observação relevante das estimações é que a perda de aprendizagem em matemática foi muito maior do que em língua Portuguesa, e esse fato está em linha com a literatura, visto que, alguns autores (Barbosa, 2005 *apud* Andrade; Soares, 2008; Rodrigues et al., 2011) indicam que, a disciplina de matemática é mais afetada pela qualidade das aulas e da escola, em relação a disciplina de língua portuguesa, que é fortemente afetada pelo capital cultural de cada aluno.

Ademais, como exposto na seção 2, Jamison *et al.* (2006) indicaram que os testes de matemática, aparentemente, mediam um elemento do capital humano importante para o crescimento da renda per capita. Nesse sentido, a queda brusca na proficiência em matemática pode representar um problema estrutural grave para o país no futuro, se não houver alguma medida de reversão ou suavização desse cenário.

Com relação as estimações baseadas nos quartis do ICH e IRF, quando consideramos este último, os resultados estão de acordo com o esperado, isto é, os alunos do primeiro quartil – piores em relação ao IRF – tiveram uma perda de aprendizagem maior do que os alunos do

quarto quartil – melhores em relação ao IRF. É relevante observar, que essa queda de aprendizagem relacionada aos recursos financeiros da escola, é consideravelmente menor do que a queda de aprendizagem relacionado ao nível socioeconômico dos estudantes. Tal resultado é coerente, considerando que, durante o período de ensino remoto, os alunos estudaram em casa, e, portanto, foram fortemente influenciados pelas condições familiares.

Nesse sentido, cabe destacar a importância da escola pública, e o seu papel na mitigação das desigualdades entre os alunos, permitindo que o conhecimento tenha acesso mais democrático. Longe das escolas, as desigualdades sociais entre alunos se destacam, fazendo com o conhecimento seja concretizado com maior facilidade para alunos com melhores condições socioeconômicas.

Ao considerarmos o ICH, observa-se que os alunos pertencentes ao primeiro quartil apresentaram uma perda de aprendizagem menor do que aqueles do quarto quartil. Em outras palavras, estudantes de escolas com menor ICH foram menos afetados do que aqueles de instituições com maior capital humano. Esse resultado é particularmente relevante, pois sugere que a qualidade do capital humano das escolas não foi transferida de forma eficaz para a modalidade de ensino remoto. Assim, mesmo instituições com equipes qualificadas não conseguiram manter os níveis de qualidade do ensino remoto durante o período.

Por fim, ao considerar as desigualdades entre as escolas, analisando apenas os extremos do ICH e do IRF, ratifica a maior perda de aprendizagem em matemática do que em português. Esse resultado é relevante, pois destaca a necessidade de atenção nas políticas educacionais para mitigação dos impactos da pandemia, assegurando estratégias direcionadas para recuperação do aprendizado, especialmente em matemática.

5 CONSIDERAÇÕES FINAIS

O cenário da pandemia da Covid-19 representou um grande desafio para todos. A maioria das pessoas precisou readaptar sua vida por completo, frente às grandes restrições impostas pela circulação do novo vírus.

Nas escolas, o ensino remoto foi uma solução adotada mundialmente, visto que, retirar alunos e professores das escolas era urgente frente a alta contagiosidade da doença. Entretanto, infelizmente, essa medida vem acompanhada de uma perda na qualidade do ensino, e consequentemente, da aprendizagem realizada.

A educação formal tem um importante papel na formação da renda individual, e na superação do ciclo da pobreza, e, portanto, devemos considerar com preocupação os efeitos que o ensino remoto e a pandemia podem ter deixado sobre as gerações afetadas. Cabe levar em conta, também, a noção de que a aprendizagem é um processo contínuo, e que se for prejudicada em determinado momento, pode seguir afetando o aluno mesmo posteriormente.

Dentro dessa realidade, essa dissertação buscou encontrar uma quantificação concreta dessa perda de aprendizagem, levando em consideração a amostra de alunos do 9º ano das escolas públicas brasileiras que realizaram a Prova SAEB. Essa amostra foi filtrada e submetida a um processo estatístico (PSM), a fim de remover possíveis vieses de seleção, e agrupar alunos semelhantes dos anos de 2019 e 2021 – antes e depois do ensino remoto.

Os resultados dessa pesquisa, indicam forte presença de perda de aprendizagem nos alunos de 2021, em relação aos de 2019. Essa perda é ainda mais severa para alunos que os pais tinham escolaridade mais baixa – potencialmente alunos mais pobres – simbolizando que, as desigualdades existentes antes da pandemia tendem a se intensificar.

Essa conclusão não é uma surpresa, tendo em vista que, alunos de famílias potencialmente mais ricas, teriam melhores condições estruturais para mitigarem os danos de aprender longe das escolas. Essa é apenas uma das maneiras de salientar como a pandemia pode ter ampliado desigualdades sociais.

Ademais, os resultados dessa pesquisa indicaram que, as desigualdades sociais tiveram um impacto maior do que as desigualdades escolares na potencialização da perda de aprendizagem. Podemos entender que, longe das escolas, as desigualdades sociais se concretizam com maior facilidade, como elemento influenciador da realização do aprendizado. As escolas públicas são muito importantes na mitigação dessas desigualdades, e na possibilidade de acesso democrático ao ensino.

Em declaração, diretores da pasta da Educação da Unesco em 30 de março de 2022, relataram com preocupação o fato de que, menos da metade dos países estava implementando estratégias em escala para recuperação da aprendizagem perdida durante a pandemia.

No Brasil, há um projeto de lei em tramitação no Senado, que institui regras para recuperação da perda educacional, de autoria do senador Rogério Carvalho (PT-SE), que estabelece que as escolas devam adotar uma ou mais das seguintes normas: tutoria individualizada ou em grupos de 4 alunos que atenda os estudantes pelo menos três vezes na semana; ampliação da quantidade de dias letivos em, ao menos, 10%; ou dobrar a carga horária das disciplinas de português e matemática.

Essas medidas são interessantes, mas surge a dúvida de se a rede pública conseguiria adotá-las sem que houvesse um comprometimento real do poder público na questão do investimento, tanto na contratação de professores para as tutorias ou na melhoria e ampliação das estruturas escolares para que fosse possível abrigar a carga horária adicional, sem comprometer outras disciplinas.

De qualquer forma, muito próximo de cinco anos após a declaração da pandemia, o tema da educação não parece ser tratado com a urgência necessária, enquanto gerações saem das escolas com a “herança” do ensino remoto não tendo sido devidamente endereçada. Em 2021, um estudo do Insper e do Instituto Unibanco estimou uma redução coletiva de R\$ 700 bilhões na renda do trabalho futuro de estudantes brasileiros.

Essa dissertação deixa indicações concretas da perda de aprendizagem generalizada, e, principalmente, nas camadas menos favorecidas. Se as perspectivas se confirmarem, de que essa perda significará redução salarial no futuro, o Brasil pode estar à beira de um grave problema de ampliação da desigualdade social. Cabe ao poder público priorizar esse tema o mais rápido possível, não apenas sugerindo medidas, mas encontrando maneiras de fazer com que uma rede pública de ensino sobrecarregada consiga aplicá-las.

As limitações dessa dissertação estão na impossibilidade de acompanhar o mesmo aluno, antes e depois do ensino remoto. Essa situação seria ideal, para efeito da análise e foi simulada a partir do PSM. Além disso, seria importante construir índices mais robustos para as características escolares, assim como, um índice próprio para infraestrutura das escolas (bibliotecas, laboratórios de informática etc.), entretanto, esbarrou-se em limitações dos questionários, como falta de questões, ou, por vezes, com algumas perguntas que existiam em um dos anos, mas não no outro.

Outro obstáculo foi o fato dos códigos do SAEB não serem unificados com os códigos do IBGE. Nesse sentido, não foi possível mesclar os dados desse sistema com os dados do

Censo Escolar, por exemplo. Ainda sobre o sistema SAEB, os códigos de escola não são sequer unificados entre os anos, ou seja, a mesma escola tem códigos diferentes em 2019 e 2021, o que impossibilitou alguns tipos de estimações.

Uma possibilidade para extensão dessa pesquisa, é consolidar as estimações com os novos dados da Prova SAEB de 2023, que estão em processamento e devem ser disponibilizados em breve. Os dados de 2023 podem mostrar alguma recuperação da perda de aprendizagem, e um avanço para retomada do crescimento que se observava anteriormente a pandemia. Por outro lado, é possível verificar uma maior queda na aprendizagem, caso os efeitos do ensino remoto sejam persistentes, ou ainda, uma estabilização no nível de aprendizagem de 2021. De qualquer forma, pode enriquecer a literatura dos efeitos da pandemia na educação.

REFERÊNCIAS

- ALVES, M. T. G.; SOARES, J. F. Efeito-escola e estratificação escolar: o impacto do uso da habilidade dos alunos na composição de turmas. **Educação em Revista**, Belo Horizonte, n.45, p.25-59, 2007.
- ALVES, T. A relação entre desempenho escolar, condições de oferta de ensino e origem sócio-econômica em escolas da rede pública de ensino. [s. l.], 1 jan. 2007. .
- AMORIM, Gabriel Brito; CÓ, Elisa Prado; FINARDI, Kyria Rebeca. Percepções de alunos sobre os impactos da pandemia na educação: foco no aprendizado de inglês. **Revista Práxis**, v. 3, p. 4-31, 2021.
- ANDRADE, Josemberg M. de; LAROS, Jacob A. Fatores associados ao desempenho escolar: estudo multinível com dados do SAEB/2001. **Psicologia: Teoria e Pesquisa**, v. 23, n. 1, p. 33-41, 2007.
- ANDRADE, Rita de. Teoria do Capital Humano e a Qualidade da Educação nos Estados Brasileiros. Trabalho de Conclusão (Graduação em Economia), Faculdade de Ciências Econômicas da UFRGS, Porto Alegre, 2010.
- ANDRADE, R. J.; SOARES, J. F. O efeito da escola básica brasileira. **Estudos em Avaliação Educacional**, v. 19, n. 41, p. 379-406, set.-dez. 2008.
- ARAÚJO, F. R. A. de; SIQUEIRA, L. B. O. de. Determinantes do Despenho Escolar dos Alunos da 4ª série do Ensino Fundamental no Brasil. **Escola e Desenvolvimento**, Recife, v.9, n.1, 2010.
- ARDINGTON, C.; WILLS, G.; KOTZE, J. COVID-19 learning losses: Early grade reading in South Africa. **International Journal of Educational Development**, Elsevier, v. 86, 2021.
- AZEVEDO, João Pedro *et al.* Simulating the Potential Impacts of COVID-19 School Closures on Schooling and Learning Outcomes: A Set of Global Estimates, **The World Bank Research Observer**, v. 36, n. 1, p.1–40, 2021.
- BARBOSA, A. L. de A., ANJOS, A. B. L. dos; AZONI, C. A. S. Impactos na aprendizagem de estudantes da educação básica durante o isolamento físico social pela pandemia do COVID-19. **CoDAS** (São Paulo), v. 34, n. 4, 2022.
- BARRO, Robert J. Economic growth in a cross section of countries. **Quarterly Journal of Economics**, v. 106, n. 2, p. 407-443, 1991.
- BETTINGER, Eric *et al.* Diminishing Marginal Returns to Computer-Assisted Learning. **Journal of Policy Analysis and Management**, v. 42, n. 2, p. 552-570, 2023.
- BROOKE, N.; SOARES, J. F. Pesquisa em eficácia escolar: origem e trajetórias. Belo Horizonte: EdUFMG, 2008.
- BROOKOVER, W. B. *et al.* Elementary school social climate and school achievement. **American Educational Research Journal**, v. 15, n. 2, p. 301–318, 1978.

CABRAL, P. P. A.; PIRES, L. S. L.; ISOBE, R. M. R.; REZENDE, V. M.; COSTA, A. A. d. S. Impactos da Pandemia na Alfabetização. **Cadernos da FUCAMP**, v. 35, p. 35-49, 2024

CARD, David; KRUEGER, Alan B., 1996. Labor Market Effects of School Quality: Theory and Evidence, NBER Working Papers 5450, **National Bureau of Economic Research**, Inc., 1996.

CAVALCANTI, G. S.; ANDRÉ, D. M.; ARAÚJO, J. R. Transbordamentos Espaciais da Educação nos Municípios Brasileiros. In: **XVIII Encontro Nacional Da Associação Brasileira De Estudos Regionais E Urbanos (Enaber)**. Anais[...].On-line: ABER, 2020.

CAVALCANTI, I. T. d. N. Análise dos Diferenciais de Desempenho dos Estudantes Cotistas e Não Cotistas da UFBA pelo Propensity Score Matching. Dissertação (Mestrado) – Faculdade de Economia, Universidade Estadual da Bahia, 2015.

CHEN, CY; BYRNE E; VÉLEZ T. Impact of the 2020 pandemic of COVID-19 on Families with School-aged Children in the United States: Roles of Income Level and Race. **Journal of Family Issues**; v. 43, n.3, p. 719-740, 2022.

COLEMAN, J. S. *et al.* Equality of education opportunity. Washington, DC: US Department of Health, Education & Welfare, 1966.

COSTA, A. E. R.; NASCIMENTO, A.W. R. do. Os desafios do ensino remoto em tempos de pandemia no brasil. Anais VII CONEDU - Edição Online. Campina Grande: Realize Editora, 2020.

COUTO, Edvaldo Souza *et al.* #fiqueemcasa: educação na pandemia da COVID-19. **Interfaces Científicas-Educação**, v. 8, n. 3, p. 200-217, 2020.

CURRIE, J.; THOMAS, D. Early test scores, school quality and SES: Longrun effects on wage and employment outcomes; In: Worker Wellbeing in a Changing Labor Market. **Research In Labor Economics**, Vol. 20, Emerald Group Publishing Limited, Leeds, pp. 103-132, 2001.

DAEB, INEP. Relatório dos Resultados do SAEB 2019, v.1. Disponível em: <https://download.inep.gov.br/educacao_basica/saeb/2019/resultados/relatorio_de_resultados_do_saeb_2019_volume_1.pdf>. 2022. Acesso em: 05/2024

DAEB, INEP. Relatório dos Resultados do SAEB 2021, v.1. Disponível em: <https://download.inep.gov.br/educacao_basica/saeb/2021/resultados/relatorio_de_resultados_do_saeb_2021_volume_1.pdf>. 2023. Acesso em 05/2024

DA SILVA, Mirian Souza; DE CARVALHO, Mark Clark Assen. Percurso do SAEB no Brasil: história e debate. **Humanidades & Inovação**, v. 9, n. 3, p. 27-39, 2022.

ENGELHARDT, B.; JOHNSON, M.; MEDER, M. Learning in the time of Covid-19: Some preliminary findings. **International Review of Economics Education**, [s. l.], v. 37, jun. 2021. <https://doi.org/10.1016/j.iree.2021.100215>.

ENGZELL, P.; FREY, A.; VERHAGEN, M. D. Learning Loss Due to School Closures during the COVID-19 Pandemic. **Proceedings of the National Academy Of Sciences**, 118, 2021.

FERREIRA, Diego. OLIVEIRA, Victor R. de. Violência e desempenho dos alunos nas escolas brasileiras: uma análise a partir do SAEB 2011. **Revista Econômica - Niterói**, v.15, n. 1, p.84-114, 2013.

FUJITA, L. D. V.; BAGOLIN, I. P.; FOCHEZATTO, A. Spatial distribution and dissemination of education in Brazilian municipalities. **The Annals of Regional Science**, v. 66, n. 2, p. 255-277, 2021.

GILLITZER, C.; PRASAD, N. The effect of school closures on standardized test scores: Evidence under zero-COVID policies. **Economics of Education Review**, [s. l.], v. 102, out. 2024. <https://doi.org/10.1016/j.econedurev.2024.102577>.

GREWENIG, E.; LERGETPORER, P.; WERNER, K.; WOESSMANN, L.; ZIEROW, L. COVID-19 and educational inequality: How school closures affect low- and high-achieving students. **European Economic Review**, [s. l.], v. 140, 2021. DOI: 10.1016/j.euroecorev.2021.103920.

GUARISO, A.; NYQVIST, M. The impact of the COVID-19 pandemic on children's learning and wellbeing: Evidence from India. **Journal of Development Economics**, [s. l.], v. 164, set. 2023. <https://doi.org/10.1016/j.jdeveco.2023.103133>.

JAMISON, Eliot A.; JAMISON, Dean T.; HANUSHEK, Eric A. The Effects of Education Quality on Income Growth and Mortality Decline," NBER Working Papers 12652, **National Bureau of Economic Research**, Inc, 2006.

HANUSHEK, E. The value of teachers in teaching. Santa Monica: Rand Corporation, 1970.

HANUSHEK, E; WOESSMANN, L. Do better schools lead to more growth? Cognitive skills, economic outcomes, and causation, **Journal of Economic Growth**, v. 17, n. 4, 267-321, dez. 2012.

HANUSHEK, E. Economic growth in developing countries: The role of human capital. **Economics of Education Review**, v. 37, p. 204-212, 2013.

HANUSHEK, E; KIMKO, Dennis D. Schooling, Labor-Force Quality, and the Growth of Nations, **The American Economic Review**, v. 90, n. 5, p. 1184–1208, 2000.

HEPPEN, Jessica B. *et al.* The Struggle to Pass Algebra: Online vs. Face-to-Face Credit Recovery for At-Risk Urban Students. **Journal of Research on Educational Effectiveness**. 2016.

IBGE. Pesquisa Nacional por Amostra de Domicílios (PNAD) 2014. Disponível em:<<http://www.ibge.gov.br>> . Acesso em: 08/2024.

IKEDA, M.; YAMAGUCHI, S. Online learning during school closure due to COVID-19. **Japanese Economic Review**, [s. l.], v. 72, n. 3, p. 471–507, jul. 2021. <https://doi.org/10.1007/s42973-021-00079-7>.

INEP. Apresentação dos Resultados do PISA 2022. Disponível em: <https://download.inep.gov.br/acoes_internacionais/pisa/resultados/2022/apresentacao_pisa2022_brazil.pdf>. 2023. Acesso em: 04/2024

INEP. Nota Técnica – Indicador de Nível Socioeconômico do SAEB 2021. Disponível em: <https://download.inep.gov.br/areas_de_atuacao/Indicadores_de_nivel_Nota_tecnica_2021.pdf>. 2023. Acesso em: 09/2024

JENCKS, C. Inequality: a reassessment of the effect of family and schooling in America. London: Lowe & Brydone, 1972.

JESUS, G. R. de; LAROS, J. A. Eficácia escolar: regressão multinível com dados de avaliação em larga escala. **Avaliação Psicológica**, Campinas, v. 3, n. 2, p. 93-106, nov. 2004.

KOSLINSKI, M.C.; ALVES, F. Novos olhares para as desigualdades de oportunidades educacionais: a segregação residencial e a relação favela-asfalto no contexto carioca. **Educação & Sociedade**, v. 33, n.120, p. 783-803, 2012.

LICHAND, G. *et al.* The impacts of remote learning in secondary education during the pandemic in Brazil. **Nature Human Behavior**, v. 6, p. 1079–1086, 2022.

LINS BELLON, L.; DA CRUZ LIMA, A. C. Uma Análise Espacial da Relação Entre Saneamento Básico e Educação nos Municípios Brasileiros. **Revista Brasileira de Estudos Regionais e Urbanos**, [S. l.], v. 15, n. 4, p. 629–655, 2022.

MACHADO, Ana Flávia *et al.* Qualidade do ensino em matemática: determinantes do desempenho dos alunos em escolas públicas estaduais mineiras. **Revista Economia**, v. 9, n. 01, p. 23-45, jan/abr., 2008.

MALDONADO, Joana Elisa; DE WITTE, Kristof. The effect of school closures on standardised student test outcomes. **British Educational Research Journal**, v. 48, n. 1, p. 49-94, 2022.

MORTIMORE, P.; STONE, C. Measuring Educational Quality. **British Journal of Educational Studies**, 39, p. 69-82, 1991.

MORTIMORE, P. The Vital Hours: Reflecting on Research on Schools and their Effects. In: Hargreaves, A., Lieberman, A., Fullan, M., Hopkins, D. International Handbook of Educational Change. **Kluwer International Handbooks of Education**, vol 5. Springer, Dordrecht. 1998, p. 85-99.

MUIJS, D. New Directions for School Effectiveness Research: Towards School Effectiveness Without Schools. **Journal of Educational Change**, v.7, p.141–160, 2006.

MUMTAHENA, F.; SEN, K.; SAYYED, M.; WIJAYAWARDHANA, P.; ZAFARI, R.; KAFLE, S. Learning Losses of Undergraduate Students in South Asia during COVID-19 and its Determinants. **Economic Papers**, [s. l.], v. 42, n. 4, p. 366–394, dez. 2023. <https://doi.org/10.1111/1759-3441.12402>.

NAKABASHI, L. SALVATO, M. A. Human capital quality in the brazilian states. **Revista Economia**, v.8, n. 2, p. 211-229, maio/ago, 2007.

OECD, PISA 2022 Results (Volume I): The State of Learning and Equity in Education, PISA, OECD Publishing, Paris, <<https://doi.org/10.1787/53f23881-en>>. 2023. Acesso em: 04/2024.

ORGANIZAÇÃO PAN-AMERICANA DE SAÚDE. Histórico da pandemia de Covid-19. Disponível em: <<https://www.paho.org/pt/covid19/historico-da-pandemia-covid-19>>. Acesso em: ago/2024. Acesso em: 05/2024.

PINTO, Santiago. The Pandemic's Effects on Children's Education. **Federal Reserve Bank of Richmond Economic Brief**, N. 23-29, 2023.

PLOWDEN, B. Children and Their Primary Schools: A Report of the Central Advisory Council of Education England. London: H.M.S.O. 1967.

PSACHAROPOULOS, George. PATRINOS, Harry A. Returns to investment in education: a further update. **Education Economics**, v.12, n. 2, p. 111-134, 2004.

RAIHER, A. P. A evolução do capital humano e sua importância no crescimento econômico das microrregiões paranaenses no período de 1999 – 2006. Tese (Doutorado em Economia) – UFRS, Faculdade de Ciências Econômicas, Programa de Pós-Graduação em Economia, Porto Alegre, 2009.

RAIHER, A. P. Políticas de cotas na UEPG: análise do abandono e do rendimento acadêmico. **Estudos em Avaliação Educacional**, v.33, e08475, 2022.

RAMOS, S.; CORDEIRO, J. K. R. Desafios do professor da educação infantil no contexto da pandemia Covid-19. **Research, Society and Development**, [s. l.], v. 11, n. 8, p. e15611830850, 13 jun. 2022. <https://doi.org/10.33448/rsd-v11i8.30850>.

RIANI, J. L. R.; RIOS-NETO, E. L. G. Background familiar versus perfil escolar do município: qual possui maior impacto no resultado educacional dos alunos brasileiros? **Revista Brasileira de Estudos de População**, v. 25, n. 2, p. 251-269, jul./dez. 2008.

RODRIGUES, C. G.; RIOS-NETO, E. L. G.; PINTO, C. C. de X. Diferenças intertemporais na média e distribuição do desempenho escolar no Brasil: o papel do nível socioeconômico, 1997 a 2005. **Revista Brasileira de Estudos de População**, v. 28, n. 1, jan./jun. 2011.

ROSENBAUM, P. R., RUBIN, D. B. The Central Role of the Propensity Score in Observational Studies for Causal Effects. **Biometrika**, v. 70, n.1, 41-55, 1983.

SCHEERENS, J. School effectiveness research and the development of process indicators of school functioning. **School Effectiveness and School Improvement**, v. 1, n. 1, p. 61-80, 1990.

SCHULTZ, Theodore W. Investment in human capital. **The American Economic Review**, v. 51, n. 1, p. 1-17, março.1961.

SMEEDING, Timothy. Poor People in Rich Nations: The United States in Comparative Perspective. **Journal of Economic Perspectives**, v.20, n.1, p. 69–90, 2006.

SOARES, J. F. O Efeito da escola no desempenho cognitivo de seus alunos. **Revista Electrónica Iberoamericana sobre Calidad, Eficácia y Cambio en Educación**. v. 2, n. 2, p. 83 104, 2004.

SOARES, T. M.; MENDONÇA, M. C. M. Construção de um modelo de regressão hierárquico para os dados do Simave-2000. **Pesquisa Operacional**, v. 23, n. 3, p. 421-441, set./dez. 2003.

SOARES, J. F. *et. al* Fatores associados ao desempenho em língua portuguesa e matemática: a evidência do SAEB-2003. Belo Horizonte: Laboratório de Medidas Educacionais, Instituto de Ciências Exatas, Universidade Federal de Minas Gerais, 2004. 74 p. Relatório Técnico.

SOUSA, I. M.; LUCENA, W. G. L. Uma análise do desempenho dos alunos na II Olimpíada Brasileira de Educação Financeira durante a pandemia do coronavírus. **Revista Capital Científico - Eletrônica**, [s. l.], v. 21, n. 4, 2023. DOI 10.5935/2177-4153.20230026.

SOUZA, W. P. S. de F.; OLIVEIRA, V. R. de; ANNEGUES, A. C.; *Background* Familiar e Desempenho Escolar: uma Abordagem Não Paramétrica. **Pesquisa e Planejamento Econômico, PPE**, v. 48, n. 2, p. 133-162, 2018.

UNESCO (2020b). COVID-19 impact on education. Disponível em: <<https://en.unesco.org/covid19/educationresponse>>. 2020. Acesso em: 04/2024

VIEIRA, M. de F.; SECO, C. M. A Educação no contexto da pandemia de COVID-19: uma revisão sistemática de literatura. **Revista Brasileira de Informática na Educação**, [S. l.], v. 28, p. 1013–1031, 2020.


WILSON, Kathryn. The effects of school quality on income. **Economics of Education Review**, v. 21, n. 6, p. 579-588, 2002.

WOESSMANN, L. *et. al*. Education in the corona crisis: How did the schoolchildren spend the time the schools were closed and which educational measures do the Germans advocate?; **Ifo Schnelldienst**, n. 3, 2020.

YARROW, N.; MASOOD, E.; AFKAR, R. Estimates of COVID-19 Impacts on Learning and Earning in Indonesia: How to Turn the Tide. **World Bank**, Washington DC, 2020.


APÊNDICE A – GRÁFICOS DE BALANCEAMENTO DO PSM

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor*: (a) covariadas e (b) função de densidade




Fonte: Elaboração própria através do *software* RStudio.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1: (a) covariadas e (b) função de densidade




Fonte: Elaboração própria através do *software* RStudio.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2: (a) covariadas e (b) função de densidade




Fonte: Elaboração própria através do software RStudio.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* do modelo ii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo ii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo ii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* do modelo iii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo iii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo iii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* do modelo iv: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo iv: (a) covariadas e (b) função de densidade



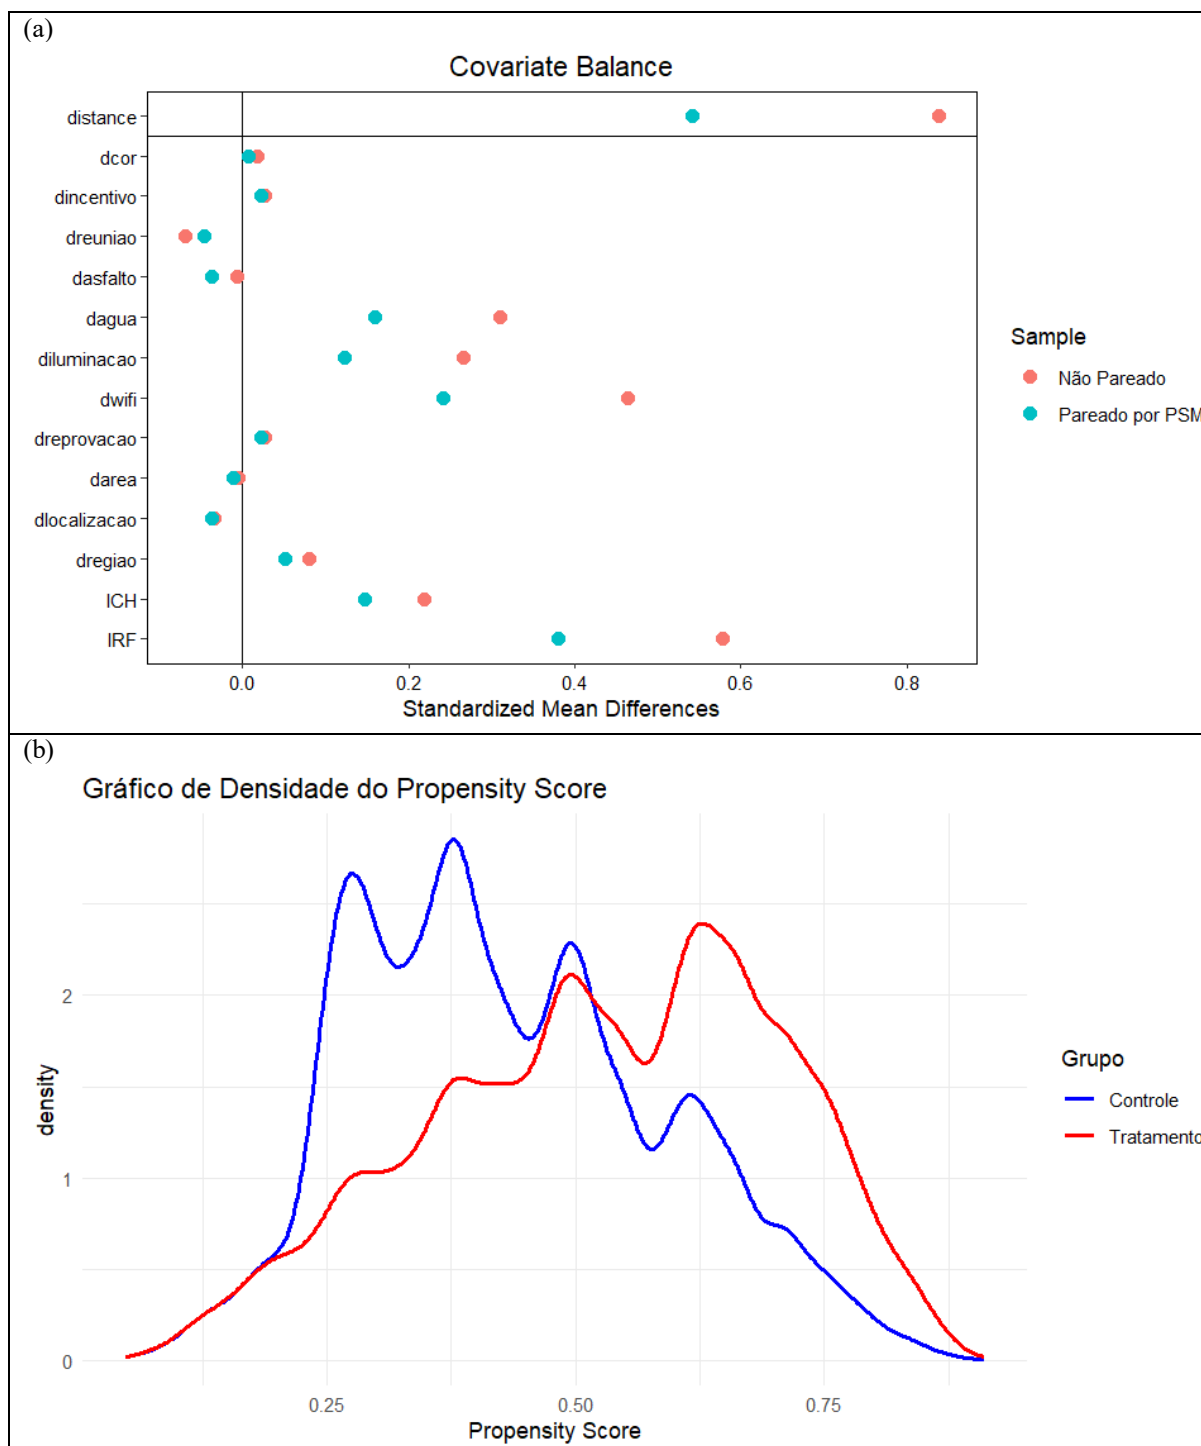
Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo iv: (a) covariadas e (b) função de densidade



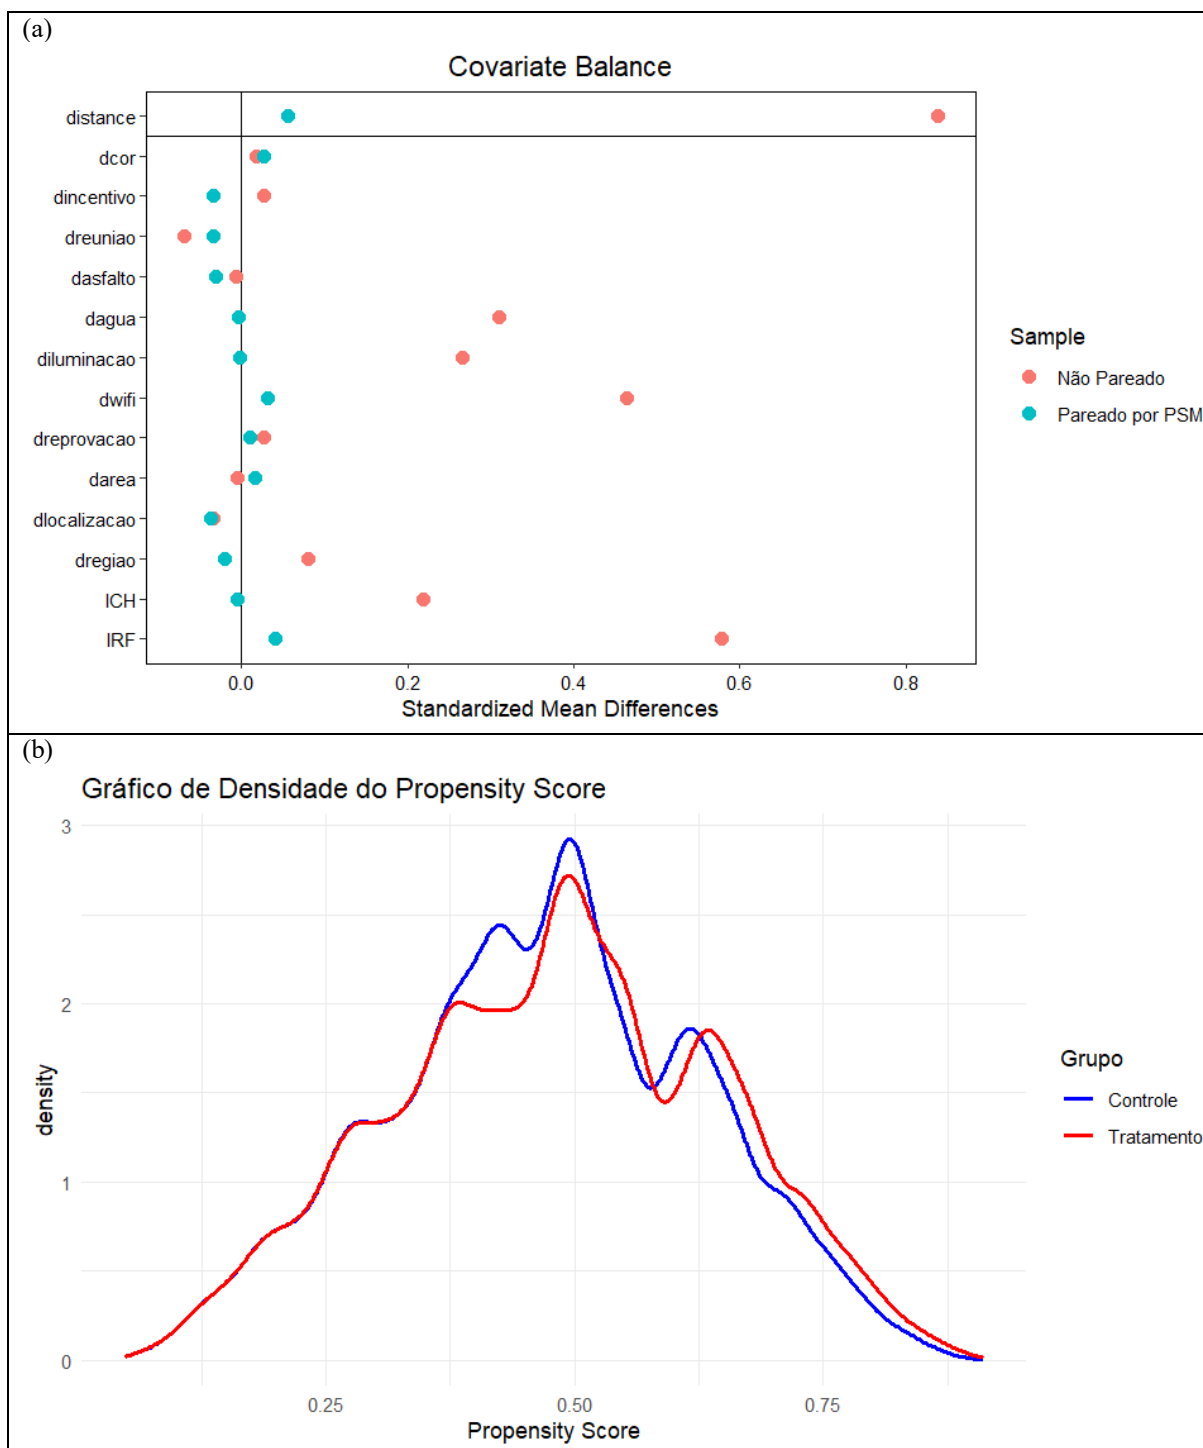
Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* do modelo v: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo v: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo v: (a) covariadas e (b) função de densidade



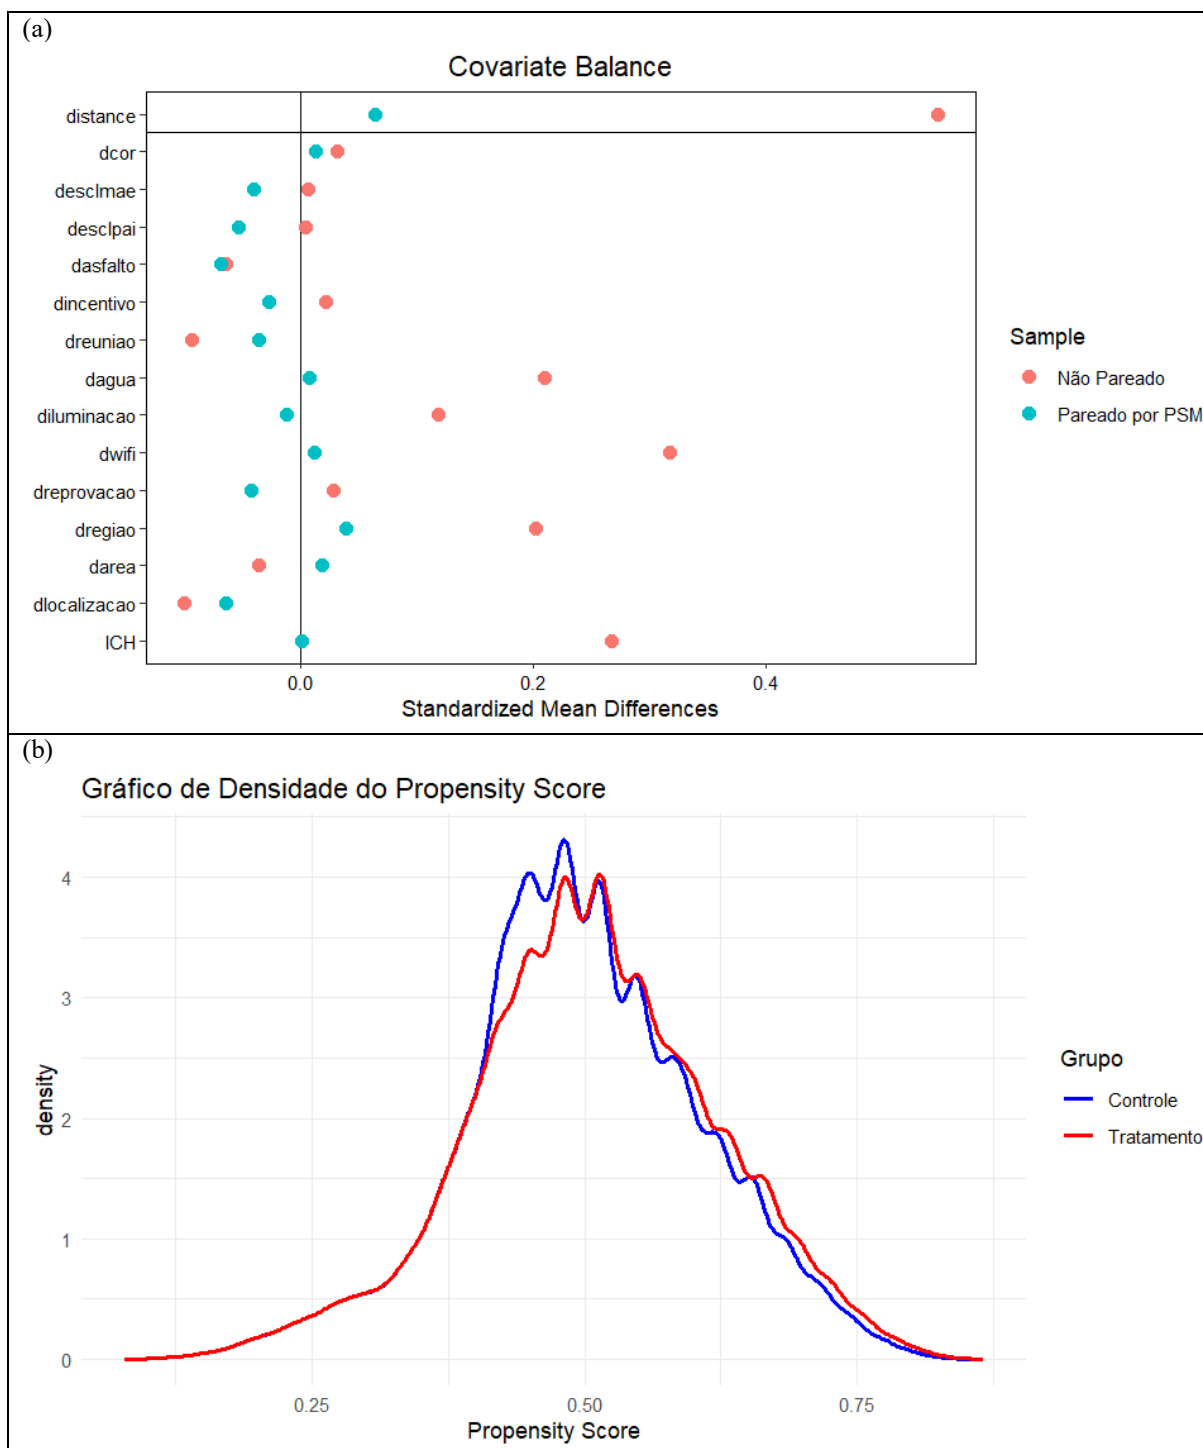
Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* modelo vi: (a) covariadas e
(b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo vi: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo vi: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* modelo vii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo vii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo vii: (a) covariadas e (b) função de densidade



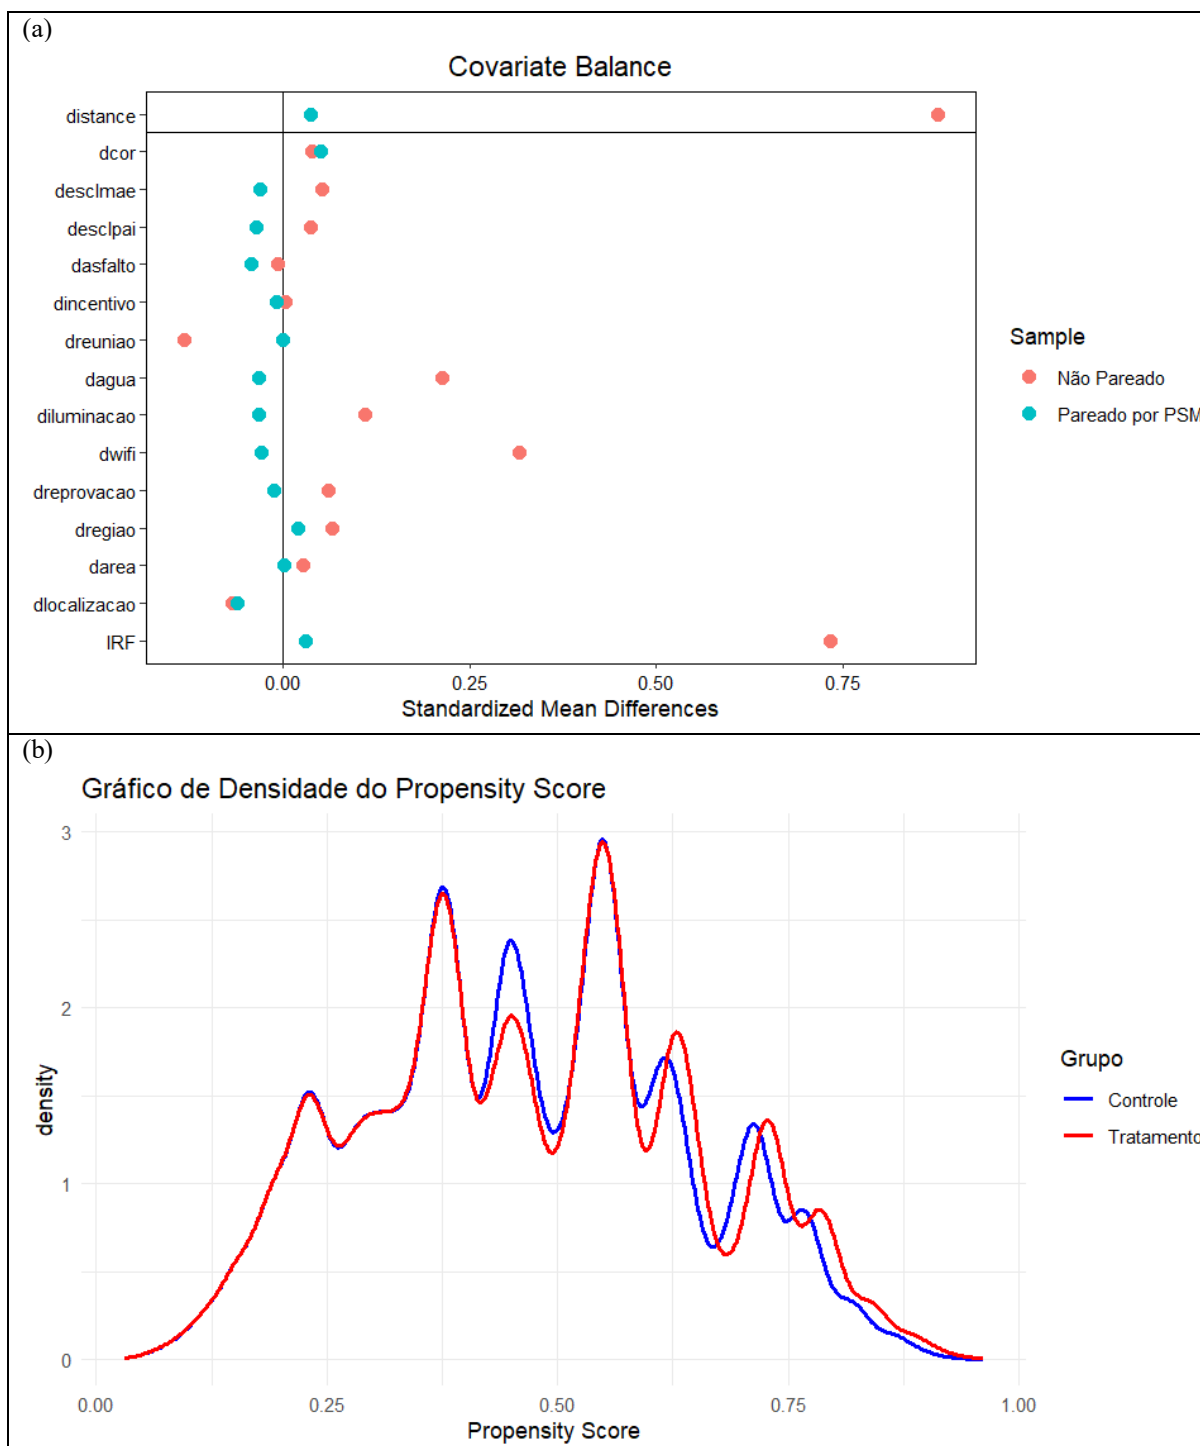
Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* modelo viii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo viii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo viii: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Nearest Neighbor* modelo ix: (a) covariadas e (b) função de densidade




Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,1 do modelo ix: (a) covariadas e (b) função de densidade



Fonte: Resultado de pesquisa.

Balanceamento pós-pareamento do algoritmo *Caliper* 0,2 do modelo ix: (a) covariadas e (b) função de densidade



Fonte: Resultado de pesquisa.