



João Gabriel Mayrinck Gelli

**O impacto das condições de acesso ao sistema de
saúde na mortalidade hospitalar em uma pandemia:
O caso da COVID-19 no Brasil**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia de Produção, do Departamento de Engenharia Industrial da PUC-Rio.

Orientador: Prof. Fernanda Araujo Baião Amorim
Co-orientador: Prof. Fernando Augusto Bozza

Rio de Janeiro
abril de 2021



João Gabriel Mayrinck Gelli

**O impacto das condições de acesso ao sistema de
saúde na mortalidade hospitalar em uma pandemia:
O caso da COVID-19 no Brasil**

Dissertação apresentada como requisito parcial para
obtenção do grau de Mestre pelo Programa de Pós-
graduação em Engenharia de Produção da PUC-Rio.
Aprovada pela Comissão Examinadora abaixo:

Prof. Fernanda Araujo Baião Amorim

Orientadora

Departamento de Engenharia Industrial - PUC-Rio

Prof. Fernando Augusto Bozza

Co-orientador

FIOCRUZ

Prof. Silvio Hamacher

Departamento de Engenharia Industrial - PUC-Rio

Prof. Otávio Tavares Ranzani

FMUSP

Rio de Janeiro, 30 de abril de 2021

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

João Gabriel Mayrinck Gelli

Graduou-se em Engenharia de Produção pela Pontifícia Universidade Católica do Rio de Janeiro – PUC-RJ, em 2018. É pesquisador do Instituto Tecgraf (PUC-RJ), atuando em projetos na área de Petróleo na Gerência de Sistemas de Apoio à Decisão e Supply Chain e como integrante do Núcleo de Operações e Inteligência em Saúde (NOIS).

Ficha Catalográfica

Gelli, João Gabriel Mayrinck

O impacto das condições de acesso ao sistema de saúde na mortalidade hospitalar em uma pandemia: o caso da COVID-19 no Brasil / João Gabriel Mayrinck Gelli; orientador: Fernanda Araujo Baião Amorim; co-orientador: Fernando Augusto Bozza. – 2021.

80 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2021.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Sistema de saúde. 3. Mortalidade hospitalar. 4. Acesso. 5. Acessibilidade. 6. COVID-19. I. Amorim, Fernanda Araujo Baião. II. Bozza, Fernando Augusto. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Agradecimentos

Aos meus pais, André e Maria Claudia, minha irmã, Maria Clara, e toda a minha família pela valorização da educação, suporte emocional incondicional, momentos frequentes de descontração e amor sempre oferecidos.

À Bel, por toda a parceria ao longo dessa extensa jornada. Seja pelos ótimos momentos juntos ou pelo apoio e motivação para superar as situações difíceis.

Ao Arthur, Erika, Bia e Luiza, pelo acolhimento e participação, mesmo que indireta, em toda esta saga.

Ao Raphael e Matheus, pela amizade de longa data e presença constante sempre que necessário.

Aos orientadores Fernanda Baião e Fernando Bozza, pelos ensinamentos, discussões, motivação e direcionamentos.

Ao Leo, pela participação fundamental no projeto, amizade e disposição para ajudar e escutar em momentos de desespero. Ao Victor e Iuri, pela troca de conhecimentos e momentos de descontração.

Ao Sílvio, por todas as oportunidades. Aos colegas de Tecgraf, Luiza, Bruno, Hudson e Isabella, pela compreensão e todo o suporte oferecido ao longo da elaboração deste projeto.

A todos do Departamento de Engenharia Industrial da PUC-Rio, por todos os ensinamentos compartilhados e incentivo nessa jornada acadêmica.

A todos os profissionais de saúde, cuja dedicação é fundamental para lidarmos com a situação da pandemia da COVID-19.

Obrigado a todos que, de alguma forma, contribuíram para a realização deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Gelli, João Gabriel Mayrinck; Amorim, Fernanda Araujo Baião (Orientadora); Bozza, Fernando Augusto (Co-orientador). **O impacto das condições de acesso ao sistema de saúde na mortalidade hospitalar em uma pandemia: O caso da COVID-19 no Brasil**. Rio de Janeiro, 2021. 80p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

A pandemia da COVID-19 infectou uma grande quantidade de indivíduos e provocou elevado número de óbitos no mundo. No Brasil, reforçou disparidades regionais no sistema de saúde e provocou elevada mortalidade hospitalar. Isto chamou a atenção para um estresse no sistema de saúde e levantou a hipótese de que o acesso desigual poderia afetar a mortalidade hospitalar na pandemia. Assim, este estudo utilizou a metodologia da Design Science Research (DSR) junto ao ciclo de vida de Ciência de Dados para identificar como o acesso ao sistema de saúde impacta na mortalidade hospitalar. O acesso ao sistema de saúde é um conceito complexo e carente de uma definição consensual, o que motivou a elaboração de uma descrição que englobasse suas múltiplas características. Uma análise qualitativa da interação entre as camadas do acesso apontou a acessibilidade como esfera central. Portanto, este trabalho utilizou dados públicos do Sistema Integrado de Vigilância Epidemiológica da Gripe (SIVEP-Gripe) para entender como a acessibilidade impactou na mortalidade hospitalar por COVID-19 no Brasil no ano epidemiológico de 2020 ao avaliar as diferenças entre aqueles que foram internados em seus municípios de residência e os que tiveram que se deslocar para outras cidades. Os resultados mostraram que 26% dos pacientes hospitalizados neste período foram internados em um município diferente do que residem. Além disso, existiu um grande deslocamento de municípios da periferia das capitais em direção às capitais. Estas periferias apresentavam elevada mortalidade hospitalar e baixo nível de recursos no sistema de saúde, o que pode ter motivado a evasão. Além disso, a partir de um modelo de regressão logística de efeitos mistos, verificou-se que aqueles que deixaram seus municípios de moradia apresentaram maior chance de óbito do que aqueles que ficaram. Isto mostrou que uma deficiência na acessibilidade impactou a mortalidade hospitalar de forma negativa.

Palavras-chave

Sistema de saúde, mortalidade hospitalar, acesso, acessibilidade, COVID-19

Abstract

Gelli, João Gabriel Mayrinck; Amorim, Fernanda Araujo Baião (Advisor); Bozza, Fernando Augusto (Coadvisor). **The impact of healthcare access on the in-hospital mortality during a pandemic: The case of COVID-19 in Brazil.** Rio de Janeiro, 2021. 80p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

The COVID-19 pandemic infected many individuals and caused a high number of deaths around the world. In Brazil, it highlighted the regional healthcare disparities and caused high in-hospital mortality. This drew attention to the system's burden and raised the question that uneven access could affect in-hospital mortality during the pandemic. Therefore, this study used the Design Science Research (DSR) methodology paired with the Data Science life cycle to identify how the healthcare access affects in-hospital mortality. Access is a complex concept, lacking a consensual definition, which motivated us to create a conceptualization that encompasses its multiple characteristics. A qualitative analysis of the interaction among the layers of this new definition pointed to accessibility as the main issue. Thus, this work used public data from the Sistema Integrado de Vigilância Epidemiológica da Gripe (SIVEP-Gripe) to better understand how it affected the in-hospital mortality among COVID-19 inpatients in Brazil during the epidemiological year of 2020. This was conducted by evaluating the differences between those hospitalized in their city of residence and those that had to go to other cities. Results showed that, in this period, 26% of inpatients were not hospitalized in their city of residence. Also, there was a noticeable flux of patients from towns on the periphery of the state capitals to the capitals. These peripheries presented higher in-hospital mortality and a lower level of healthcare resources, which may have motivated the movement. Besides, the development of a mixed effects logistic regression model evidenced that inpatients that left their cities of residence had a higher chance of death than those that stayed. This showed that a deficiency in accessibility caused a negative impact in in-hospital mortality.

Keywords

Healthcare, in-hospital mortality, access, accessibility, COVID-19.

Sumário

1	Introdução	11
1.1	Objetivos e delimitação da pesquisa	13
1.2	Relevância do trabalho	13
1.3	Estrutura do documento	13
2	Metodologia Científica	15
2.1	<i>Design Science</i> e a <i>Design Science Research</i>	15
2.2	Ciclo de Vida de Ciência de Dados	16
2.2.1	Modelos lineares generalizados	18
2.2.2	Modelos lineares generalizados com efeitos mistos	19
2.2.3	<i>Odds Ratio</i>	19
2.2.4	<i>Brier Score</i>	20
2.3	Integração da <i>Design Science Research</i> com o Ciclo de Vida de Ciência de Dados	20
3	Aplicação da metodologia DSR para analisar o impacto das condições de acesso ao sistema de saúde na mortalidade hospitalar	22
3.1	Panorama das hospitalizações por COVID-19 no Brasil	22
3.2	Análise do Impacto das Condições de Acesso na Mortalidade Hospitalar	30
3.2.1	Entendimento do Negócio	30
3.2.1.1	Acesso ao sistema de saúde e suas definições	30
3.2.1.2	Impacto do acesso ao sistema de saúde na mortalidade	32
3.2.1.3	Acesso ao sistema de saúde e a COVID-19	33
3.2.1.4	Aplicações quantitativas para o acesso ao sistema de saúde	33
3.2.1.5	Definição de um conceito de acesso unificado	37
3.2.1.6	Definição da Questão de Pesquisa	38
3.2.2	Entendimento dos Dados	39
3.2.3	Preparação dos dados	40
3.2.4	Modelagem e Avaliação	46
3.2.4.1	Descrição dos pacientes hospitalizados	46
3.2.4.2	Descrição dos municípios de origem	59
3.2.4.3	Associação entre acessibilidade e mortalidade	62
4	Conclusões	66
5	Referências Bibliográficas	68
	APÊNDICE I – Mapa do Brasil com cada município colorido a partir da classificação conforme Capital, Periferia da Capital, Outras RMs e Interior	76
	APÊNDICE II – Mortalidade hospitalar por variável demográfica	77

APÊNDICE III – Deslocamentos entre categorias de municípios por região do Brasil	78
APÊNDICE IV – Mediana, primeiro quartil e terceiro quartil de características dos municípios	79
APÊNDICE V – Correlação de Spearman entre variáveis a nível de município	80

Lista de Figuras

Figura 1 - Ciclos da DSR.	16
Figura 2 - Ciclo de Vida de Ciência de Dados	17
Figura 3 - DSR integrada ao ciclo de vida de Ciência de Dados	21
Figura 4 - Procedimento de limpeza do SIVEP-Gripe para estudo de Ranzani et al. (2021)	24
Figura 5 - Relação entre as esferas do acesso ao sistema de saúde.	38
Figura 6 - Procedimento de limpeza da base SIVEP-Gripe e definição do escopo.	41
Figura 7 - Mortalidade hospitalar para internados no município de residência ou em outro município.	51
Figura 8 - Mortalidade hospitalar comparando internados no mesmo município de residência e em outro município,	52
Figura 9 - Mortalidade hospitalar comparando internados no município de residência e fora por região de residência, número de comorbidades, internação em UTI e uso de suporte respiratório	53
Figura 10 - Matriz de correlações a nível de município	61

Lista de Tabelas

Tabela 1 - Descrição dos pacientes hospitalizados por COVID-19 e comparação entre regiões geográficas do Brasil. Adaptado de Ranzani et al. (2021).	25
Tabela 2 - Mortalidade hospitalar por região geográfica do Brasil e por utilização de recursos. Adaptado de Ranzani et al. (2021).	26
Tabela 3 - Quantidade de leitos totais e de UTI em fevereiro de 2020 por 10 mil habitantes por região. Adaptado de Ranzani et al. (2021).	28
Tabela 4 - <i>Odds ratios</i> e p-valor (significância de 95%) do modelo de regressão logística para determinação do desfecho das hospitalizações. Adaptado de Peres et al. (2021).	29
Tabela 5 - Tratamento para variáveis do SIVEP-Gripe	42
Tabela 6 - Descrição variáveis adicionais por município	43
Tabela 7 - Definição da classificação de municípios	45
Tabela 8 - RM ou RIDE associada a cada capital	45
Tabela 9 - Descrição dos pacientes hospitalizados por COVID-19 e comparação entre internações no município de residência e fora	47
Tabela 10 - Proporção de internações fora do município de residência por região do Brasil	49
Tabela 11 - Tempos e desfechos diferenciados por internação no município de residência e fora	50
Tabela 12 - Descrição dos pacientes hospitalizados por COVID-19 e comparação a partir da classificação do município de residência	54
Tabela 13 - Proporção de pacientes hospitalizados fora do município de residência por classificação	57
Tabela 14 - Matriz de deslocamentos entre o município de residência e o município de internação.	57
Tabela 15 - Deslocamentos chegando em cada categoria de município	58
Tabela 16 - Descrição das características dos municípios a partir da classificação	59
Tabela 17 - Mortalidade hospitalar dos internados em cada categoria	
Tabela 18 - Efeitos fixos do modelo	62
Tabela 19 - <i>Odds ratios</i> e p-valor (significância de 95%) do modelo de efeitos mistos para determinação do desfecho das hospitalizações	63

1

Introdução

A COVID-19, também conhecida como *Coronavirus disease 2019*, surgiu no final de 2019 na província de Wuhan, na China (Chen et al., 2020; Lu, Stratton, Tang, 2020). Causada pelo agente etiológico Sars-CoV-2, ela é uma doença respiratória grave e entre seus sintomas comuns estão a febre, desconforto respiratório, tosse e perda de olfato (Harapan et al., 2020; Menni et al., 2020; Huang et al., 2020). A rápida evolução da doença ao redor do mundo impressionou, com diversos novos países sendo infectados em um curto espaço de tempo. Isto a tornou uma questão de saúde pública de ordem global (Sohrabi et al., 2020).

Nesse contexto, a COVID-19 foi caracterizada como uma pandemia pela Organização Mundial de Saúde em 11 de março de 2020 (Gumbrecht e Howard, 2020). O primeiro caso no Brasil foi confirmado em 26 de fevereiro de 2020 (MS, 2020) e desde então os números apenas aumentaram. Até o dia 02 de janeiro de 2021 (encerramento do ano epidemiológico de 2020), foram quase oito milhões de casos e duzentas mil mortes (MS, 2021).

A quantidade de casos é tão volumosa que leva a uma grande quantidade de óbitos. Quando se entra no âmbito do sistema de saúde, a mortalidade hospitalar se destaca ao avaliar a resposta da rede para as demandas da pandemia. No Brasil, foram realizados diversos estudos com o intuito de compreender o desenvolvimento da pandemia. Eles apontaram uma mortalidade hospitalar elevada mesmo entre os jovens, com fatores como raça, nível de escolaridade, idade, gênero e região impactando neste indicador. Além disso, destacam-se disparidades entre as regiões geográficas do país, com Norte e Nordeste tendo menos recursos e pacientes destas regiões apresentando maior chance de óbito. Em resumo, os trabalhos mostraram um cenário de diferenças regionais, com um maior impacto para os sistemas de saúde mais frágeis (Ranzani et al., 2021; Peres et al., 2021).

O sistema de saúde no Brasil mostrou grande evolução ao longo do tempo ao promover um acesso mais igualitário e deixando a maior parte da população coberta por meio do Sistema Único de Saúde (SUS) (Atun et al., 2015). No entanto, a partir

do que foi mostrado por Mullachery, Silver e Macinko (2016), esta melhoria perdeu força com as crises econômicas e políticas. Assim, é necessário monitorar a equidade do acesso aos serviços médicos de maneira robusta, a partir de dados concretos (Landmann-Szwarcwald e Macinko, 2016). Isto é válido especialmente durante a pandemia da COVID-19, na qual os números mostram a magnitude da doença e o impacto que causa em todo o sistema.

As disparidades regionais relativas ao sistema de saúde existem desde antes da pandemia (Szwarcwald et al., 2016), mas ficaram explícitas com o estresse do sistema e podem estar associadas com a mortalidade. Estas disparidades e estresse podem se relacionar diretamente com o conceito de acesso ao sistema de saúde, na medida em que indivíduos de lugares distintos têm oportunidades diferentes de atingir um tratamento adequado. A literatura mostra que o acesso é um aspecto importante a ser considerado ao avaliar diferentes esferas, como a social, geográfica e econômica, tendo grande influência nos desfechos encontrados, com um acesso ruim impactando de forma negativa na mortalidade (Institute of Medicine e Millman, 1993). Logo, toda a questão do acesso ao sistema de saúde aparece com um ponto crítico e de relevância para análise.

No entanto, este é um conceito complexo, com definições diferentes na literatura, podendo representar aspectos diferentes para autores distintos (Oliver, 2004). A falta de uma definição precisa e consensual quanto ao termo traz dificuldades na coleta e interpretação de dados e, conseqüentemente, nos resultados da análise, afetando a implementação de soluções que englobem as variadas dimensões vistas na literatura.

Portanto, primeiro é preciso entender melhor este conceito e elaborar uma definição que possibilite um estudo quantitativo claro. Após a elaboração desta definição, existe uma ampla oferta de dados relativos à pandemia, que podem ser usados para propor melhorias no sistema de saúde. Isto vai ao encontro com o fato de que organizações estão utilizando abordagens de otimização, simulação e *machine learning* para melhorar seus desempenhos nos últimos anos (Fosso Wamba et al. 2015), fornecendo um ambiente propício para a implementação de uma solução de Ciência de Dados para analisar a questão do acesso ao sistema de saúde durante a pandemia da COVID-19.

1.1

Objetivos e delimitação da pesquisa

A principal questão de pesquisa a ser investigada neste trabalho é "O que caracteriza a condição de acesso de uma população aos serviços de saúde, em especial durante uma pandemia, e como tais condições de acesso impactam nos índices de mortalidade hospitalar decorrente da COVID-19 no Brasil?"

Para endereçar esta questão de pesquisa, este trabalho tem como objetivo principal conceituar e quantificar esta limitação de acesso e o seu impacto na mortalidade. Além disso, conta com os seguintes objetivos secundários:

- Realizar uma revisão da literatura acerca do conceito de acesso ao sistema de saúde e das técnicas e metodologias aplicadas para quantificá-lo;
- Caracterizar a população do Brasil que acessou o sistema de saúde durante a pandemia da COVID-19;
- Construir um modelo que aborde o acesso ao sistema de saúde pela população durante o ano epidemiológico de 2020 e associar este acesso com a mortalidade hospitalar.

1.2

Relevância do trabalho

Esta pesquisa contribui com a compreensão do que é acesso ao sistema de saúde e como quantificar seu impacto durante a pandemia. Ela ainda oferece uma aplicação nova em um contexto real no Brasil. Por fim, utiliza a metodologia científica de Design Science Research (DSR) integrada ao ciclo de vida da Ciência de Dados e expande sua abordagem para o domínio da saúde.

1.3

Estrutura do documento

Após esta seção de introdução, o presente trabalho está organizado da seguinte forma: o Capítulo 2 apresenta a fundamentação teórica da dissertação. Ele trata da metodologia da DSR, do ciclo de vida da Ciência de Dados. Também apresenta os modelos lineares generalizados com e sem efeitos mistos que serão usados, o *odds ratio*, que foi utilizado como forma de interpretação, e o *Brier Score*, escolhido como métrica de avaliação.

O Capítulo 3 emprega a metodologia descrita anteriormente para analisar a associação entre o acesso ao sistema de saúde e a mortalidade hospitalar. Foram realizadas duas iterações da DSR, apresentadas em seções separadas. A primeira delas traz um panorama da COVID-19 no Brasil e como as hospitalizações se comportaram no país. A partir dela são geradas hipóteses que alimentam a segunda iteração da DSR. Nela são apresentadas diferentes definições para o que é acesso ao sistema de saúde, como ele se relaciona com a mortalidade, com a COVID-19 e como este conceito pode ser aplicado de forma quantitativa. Posteriormente, é elaborado um novo conceito para acesso ao sistema de saúde que considera suas diferentes camadas e são usados dados públicos de hospitalizações de COVID-19 no Brasil para analisar a relação entre a acessibilidade ao sistema de saúde e a mortalidade hospitalar.

Por fim, o Capítulo 4 trará as conclusões do estudo e propostas de trabalhos futuros.

2

Metodologia Científica

Este capítulo apresenta o paradigma da *Design Science* (DS) e caracteriza a *Design Science Research* (DSR) como a metodologia científica empregada para o trabalho. Também discute o Ciclo de Vida de Ciência de Dados ao mostrar os passos utilizados para gerar a pesquisa. Além disso, traz um panorama geral das etapas do estudo e em particular dos modelos utilizados. Por fim, associa a DSR com o Ciclo de Vida de Ciência de Dados para melhor contextualizar o trabalho.

2.1

Design Science e a Design Science Research

Pesquisas científicas podem ser classificadas por meio de seus objetivos. Este trabalho se enquadra como um estudo qualitativo e quantitativo. Isto se dá por tratar tanto de uma análise conceitual sobre acesso ao sistema de saúde quanto de uma avaliação quantitativa deste (Miguel, 2007). Também é uma pesquisa descritiva e explicativa por apresentar o panorama da COVID-19 no Brasil, como o acesso ao sistema de saúde se caracteriza e argumentar de que forma este acesso impacta na mortalidade durante a pandemia (Gil, 2008).

Além disso, esta pesquisa se insere no contexto de um diferente paradigma, a *Design Science* (DS). Ele almeja especificamente auxiliar trabalhos que buscam resolver problemas reais ao tentar diminuir a distância do âmbito teórico para o prático (Lacerda et al., 2014). Dessa forma, busca integrar estas duas facetas e propor artefatos (Aken, 2004).

Para operacionalizar o DS, é preciso utilizar uma metodologia científica. Para lidar com este novo paradigma de pesquisa, surgiu a *Design Science Research* (DSR). Ela busca agregar conhecimento ao criar e avaliar de maneira científica modelos, métodos e frameworks (Hevner et al., 2004; Vaishnavi e Kuechler, 2007).

Segundo Hevner (2007), a DSR deve ser realizada de maneira iterativa e englobando três grandes ciclos. O principal deles é o Design, no qual se constrói, avalia e ajusta o artefato proposto. O ciclo de Design é complementado por outros dois: o

Ciclo de Relevância e o Ciclo de Rigor. O ciclo de Relevância liga as especificações dos especialistas ou organizações do ambiente real com as soluções. Por fim, o ciclo de Rigor trata da base teórica e científica da pesquisa para confirmar que a solução proposta é uma contribuição de pesquisa. Esta metodologia está representada na Figura 1.

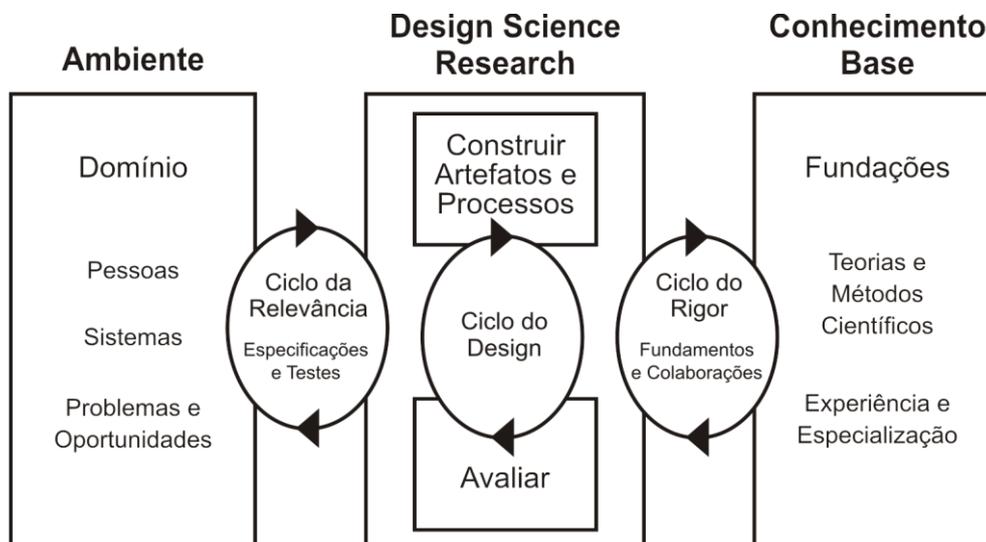


Figura 1 - Ciclos da DSR.

Fonte: Traduzido e adaptado de Hevner (2007)

2.2

Ciclo de Vida de Ciência de Dados

Este trabalho se caracteriza pela análise e descoberta de padrões de dados relativos à pandemia de COVID-19. Por isso, o ciclo do Design da DSR se comportará como um projeto de Ciência de Dados. Portanto, se faz necessário seguir alguma metodologia, como é o caso do Ciclo de Vida de Ciência de Dados.

Este foi apresentado por Shearer (2000) na estrutura do *Cross Industry Standard Process for Data Mining* (CRISP-DM). Nele, existem seis etapas na metodologia para gerar uma solução em Ciência de Dados (Shafique e Qaiser, 2014), conforme pode ser visto na Figura 2 e detalhado a seguir.

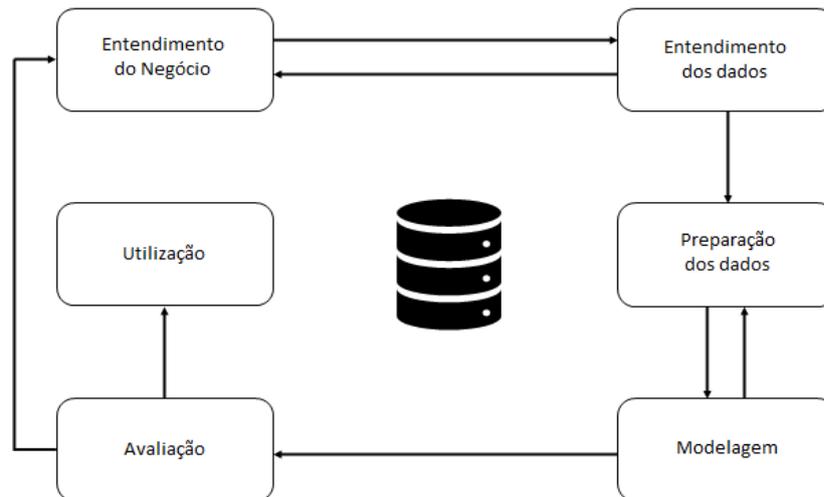


Figura 2 - Ciclo de Vida de Ciência de Dados

Fonte: Adaptado de Shearer (2000)

Primeiro, é preciso entender o negócio no qual o projeto está inserido. Nesse passo torna-se necessário compreender os objetivos e desenhar como eles podem ser traduzidos por meio de dados. A partir disso, determinar como isto será feito com as técnicas de Ciência de Dados. Nesta pesquisa, os objetivos a serem alcançados são estabelecer um panorama da pandemia de COVID-19 no Brasil, conceituar o acesso ao sistema de saúde e verificar como ele se relaciona com a mortalidade hospitalar.

A etapa seguinte envolve a compreensão dos dados. Para isso, deve-se coletar e explorar os dados que serão utilizados para analisar a qualidade deles. Então, os dados são preparados para que possam ser utilizados na modelagem. Isto é feito por meio do cruzamento de diferentes fontes, limpeza e elaboração de novas variáveis. Em particular, o presente trabalho teve como principal fonte de dados o Sistema Integrado de Vigilância Epidemiológica da Gripe (SIVEP-Gripe), que agrupa dados de pacientes hospitalizados por conta de síndromes respiratórias agudas graves. Bases de dados complementares serão apresentadas posteriormente, conforme seja pertinente.

O passo posterior é a modelagem. Nela, múltiplos modelos e parâmetros são selecionados e testados para solucionar o problema definido. Os resultados desta etapa são avaliados na fase seguinte, utilizando métricas adequadas para o domínio de acordo com os objetivos de negócio. Por fim, a utilização representa colocar a solução gerada em prática e organizar o conhecimento gerado. Nos dois ciclos de DSR conduzidos nesta pesquisa, os modelos aplicados foram os modelos lineares generalizados, especificamente a regressão logística, com e sem efeitos mistos. Eles

foram interpretados com o uso do *odds ratio* e avaliados a partir do *Brier Score*. Por fim, a etapa de utilização tem por objetivo fazer uso do modelo construído e do conhecimento descoberto no ambiente real.

2.2.1

Modelos lineares generalizados

Uma regressão consiste em estimar uma variável dependente (ou resposta) com base em uma série de variáveis independentes, chamadas de preditores. Isto pode ser feito com o intuito de gerar previsões ou então de analisar a relação entre as variáveis (Schneider, Hommel e Blettner, 2010).

Os modelos de regressão linear têm como objetivo modelar o valor esperado de uma variável contínua. No entanto, quando os problemas são lineares e apresentam desfechos dados por variáveis que representam contagens ou são binárias, é necessário utilizar os modelos lineares generalizados (MLG). Eles também englobam os casos contínuos, servindo como uma verdadeira generalização (Nelder e Wedderburn, 1972; McCullagh e Nelder, 1998).

De acordo com Faraway (2006), um MLG é definido quando a variável resposta faz parte da família exponencial, como por exemplo as distribuições Normal, Poisson e Binomial. Além disso, necessita de uma função de ligação, cujo objetivo é explicar a relação entre a média do desfecho e a combinação linear dos preditores.

Englobada nesta classe dos MLGs está a regressão logística, que será utilizada nesse trabalho e trata uma variável de desfecho binário. Ela usa a função logit como função de ligação e tem sua formulação apresentada a seguir.

$$\ln\left(\frac{p}{1-p}\right) = X\beta + \varepsilon \quad (2.1)$$

Nela, o lado direito representa o vetor de respostas com a função de ligação logit, na qual p é a probabilidade de o evento de interesse acontecer, X é a matriz de variáveis preditivas e β é o vetor com os coeficientes da regressão dos efeitos fixos. Por fim, ε é um vetor de erros aleatórios residuais.

Para interpretar os resultados dos MLGs, também pode ser utilizado o *odds ratio*, que será apresentado na Seção 2.2.3. Além disso, os modelos são avaliados com o *Brier Score*, apresentado na Seção 2.2.4.

2.2.2

Modelos lineares generalizados com efeitos mistos

Quené e Van den Bergh (2008) apontam que quando as múltiplas observações da amostra puderem ser agrupadas em uma determinada classificação, os valores de níveis mais baixos podem ser dependentes daqueles de níveis mais altos. Isto pode ser visualizado em casos como estudantes (nível mais baixo) em uma escola (nível mais alto) ou pacientes atendidos (nível mais baixo) por um médico (nível mais alto).

A partir desses níveis são definidos os chamados efeitos fixos e efeitos aleatórios. Gelman (2006) define os fixos como aqueles que são constantes entre os diferentes grupos da amostra. Enquanto isso, os aleatórios são variáveis agrupadoras (Magezi, 2015), que oferecem mais uma fonte de variação aleatória nos modelos além dos erros residuais (Oberge e Mahoney, 2007).

Segundo Breslow e Clayton (1993), a estrutura de um MLG consegue comportar variáveis como efeitos fixos e aleatórios. Assim, tem-se um modelo linear generalizado misto (MLGM). No caso deste trabalho, a variável dependente é binária, então a função de ligação apresentada é a logit. Dessa forma, tem-se uma regressão logística de efeitos mistos, que tem a seguinte formulação.

$$\ln\left(\frac{p}{1-p}\right) = X\beta + Zb + \varepsilon \quad (2.2)$$

Nela, o lado direito representa o vetor de respostas com a função de ligação logit, na qual p é a probabilidade de o evento de interesse acontecer, X é a matriz de variáveis preditivas e β é o vetor com os coeficientes da regressão dos efeitos fixos. Z é a matriz das variáveis dos efeitos aleatórios e b é um vetor de parâmetros de efeitos aleatórios. Por fim, ε é um vetor de erros aleatórios residuais.

Para interpretar os resultados dos MLGMs, também pode ser utilizado o *odds ratio*, que será apresentado na Seção 2.2.3. Além disso, os modelos são avaliados com o *Brier Score*, apresentado na Seção 2.2.4.

2.2.3

Odds Ratio

Odds ratio (OR) se apresenta como um método para interpretar a associação de uma variável com o desfecho. Ela é determinada a partir dos coeficientes da regressão. Em uma regressão logística, como é o caso deste trabalho, os coeficientes β são provenientes da função logit e são conhecidos como *log odds*, uma vez que ainda estão

na forma logarítmica. Para converter estes valores para uma escala linear, basta utilizar a fórmula e^β . Assim, tem-se o valor do *odds ratio*, que é um valor entre 0 e infinito (Sperandei, 2014).

De acordo com Andrade (2015), o *odds ratio* é a razão entre as chances de ocorrência de um evento para um grupo e as chances de ocorrência desse mesmo evento para um valor de referência. Um OR maior do que 1 representa que existe uma maior chance de ocorrência do evento, enquanto um menor do que 1 configura uma menor chance.

Além disso, no contexto de modelos de efeitos mistos, os valores dos ORs são calculados da mesma maneira. No entanto, é importante ressaltar que sua interpretação considera que os efeitos aleatórios são fixados (Hubbard et al., 2010).

2.2.4

Brier Score

O *Brier Score* é uma métrica de avaliação elaborada por Brier (1950). Ela tem como objetivo medir a precisão de previsões probabilísticas e aponta a confiança que se pode ter no modelo. Ela tem a seguinte fórmula:

$$Brier = \frac{1}{N} * \sum_{t=1}^N (f_t - o_t) \quad (2.3)$$

Nela, para um determinado caso t, f_t é a probabilidade estimada pelo modelo e o_t é o desfecho real, enquanto N é a quantidade total de casos. O *Brier Score* varia de 0 a 1 e quanto mais próximo de zero, melhores são as estimativas do modelo. Dessa forma, a métrica penaliza com maior severidade probabilidades elevadas para a classe errada.

2.3

Integração da *Design Science Research* com o Ciclo de Vida de Ciência de Dados

Para integrar os conceitos da DSR com o Ciclo de Vida de Ciência de Dados, Pérez (2020) propõe uma nova metodologia, que foi utilizada no presente trabalho. Nela, a pesquisa começa com o entendimento do negócio, que alimenta o ciclo de Design.

No ciclo de Design, os outros passos que compreendem o Ciclo de Vida de Ciência de Dados são executados. Eles são o entendimento dos dados, a preparação dos dados e a modelagem e avaliação. Dessa forma, este *framework* engloba também toda a compreensão e preparação dos dados para serem usados na construção de modelos. Tudo isso é feito com base no conhecimento teórico adquirido ao longo do ciclo do Rigor. A Figura 3 ilustra como se dá esta integração.

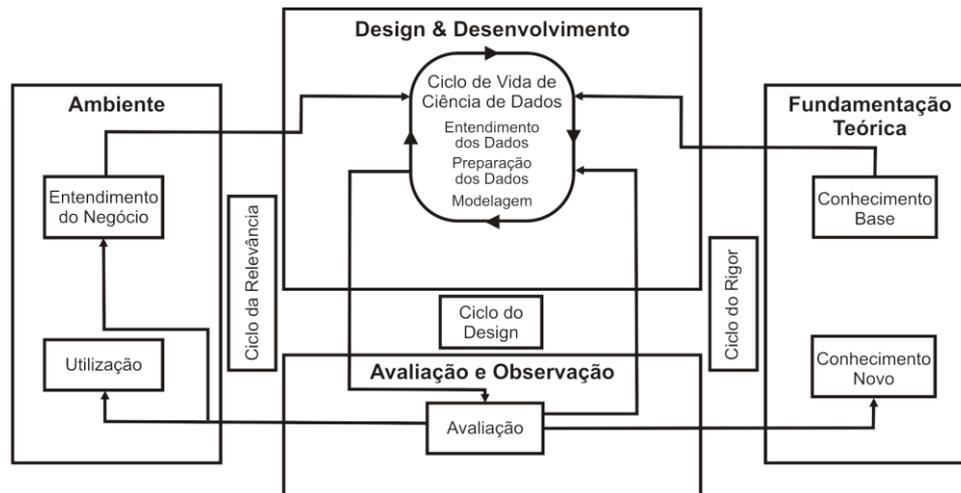


Figura 3 - DSR integrada ao ciclo de vida de Ciência de Dados

Fonte: Traduzido e adaptado de Pérez (2010)

3

Aplicação da metodologia DSR para analisar o impacto das condições de acesso ao sistema de saúde na mortalidade hospitalar

Este capítulo descreve o projeto de Ciência de Dados executado para analisar o impacto das condições de acesso ao sistema de saúde na mortalidade durante a pandemia de COVID-19 no Brasil. O trabalho seguiu a metodologia da DSR e apresentou dois ciclos.

O primeiro ciclo traz um panorama das hospitalizações por COVID-19 no Brasil. Nele são apresentados dados que mostram como as diferentes regiões e camadas demográficas foram afetadas pela doença no país. A partir das conclusões dessa análise, destacou-se a necessidade de estudar a questão do acesso ao sistema de saúde.

Dessa forma, o segundo ciclo tem como objetivo analisar como o acesso se relaciona com a mortalidade hospitalar. Para isso, primeiro é realizada uma revisão na literatura acerca do conceito de acesso para depois propor uma nova definição que englobe os diversos pontos estudados. Em seguida, este novo conceito é analisado para elaborar um estudo quantitativo. Para isso, é feita uma descrição dos pacientes hospitalizados e de seus municípios de residência. Por fim, são construídos modelos para estabelecer as relações entre as múltiplas esferas do acesso ao sistema de saúde e a mortalidade hospitalar.

3.1

Panorama das hospitalizações por COVID-19 no Brasil

A pandemia da COVID-19 promove um extenso desafio para os sistemas de saúde, na medida em que provoca um aumento da necessidade por recursos médicos, sejam eles leitos gerais, de UTI ou então equipamentos como respiradores. Isso aparece nos números de casos e, eventualmente, hospitalizações.

No caso do Brasil, destaca-se o Sistema Único de Saúde (SUS), que tem como intuito oferecer um acesso universal, trazendo equidade ao sistema de saúde do país. No entanto, Szwarcwald et al. (2016) mostraram que existem grandes diferenças entre

as cinco regiões geográficas do país e Marinho et al. (2018) também discutiram as divergências dos indicadores de saúde para cada estado mesmo antes da pandemia.

Com a pandemia da COVID-19, a rede de saúde passou a receber um volume elevado de casos. Estes começaram a chegar pelas capitais e se espalharam rapidamente pelo país. Primeiro, passaram pelas grandes cidades e então se expandiram pelas regiões metropolitanas em direção ao interior, em localidades menos populosas (de Souza et al., 2020; Candido et al., 2020).

Até 02 de janeiro de 2021, data em que terminou o ano epidemiológico de 2020, foram 7716405 (sete milhões, setecentos e dezesseis mil, quatrocentos e cinco) casos no Brasil, com 195725 (cento e noventa e cinco mil, setecentos e vinte e cinco) óbitos (MS, 2021). Isto desafia o sistema e potencialmente expõe de forma ainda mais forte as diferenças regionais. Dessa forma, no primeiro ciclo metodológico desta pesquisa procura-se entender como a doença se comportou no território brasileiro ao longo dos primeiros meses da pandemia, com foco nas regiões geográficas. Parte dos achados aqui reportados estão publicados em Ranzani et al. (2021) e Peres et al. (2021).

Como fonte de dados principal para ambos os estudos foi utilizada a base de dados do Sistema Integrado de Vigilância Epidemiológica da Gripe (SIVEP-Gripe), que traz hospitalizações no território brasileiro provenientes de síndromes respiratórias agudas graves (DATASUS, 2020a).

Também foram usados dados de bases de dados secundárias. A primeira delas foi o Cadastro Nacional de Estabelecimentos de Saúde (CNES), que traz os dados relativos a leitos disponíveis nos hospitais do país (DATASUS, 2020b). Já as estimativas populacionais foram extraídas do Instituto Brasileiro de Geografia e Estatística (IBGE, 2020a).

Para os dados do SIVEP-Gripe, no trabalho de Ranzani et al. (2021), foram selecionados apenas casos de pacientes adultos (20 anos ou mais) hospitalizados com COVID-19 confirmado por meio do teste RT-PCR. Além disso, o período observado foi o entre as semanas epidemiológicas 8 e 33 de 2020. Dessa forma, foram analisados os casos de 254288 pacientes desde o início da pandemia no Brasil até 15 de agosto de 2020. O procedimento de preparação da base para o estudo pode ser observado na Figura 4.

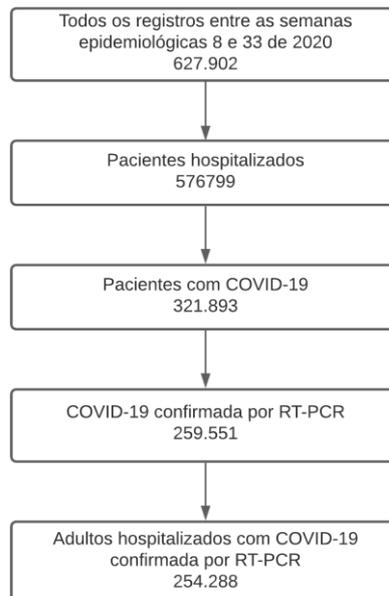


Figura 4 - Procedimento de limpeza do SIVEP-Gripe para estudo de Ranzani et al. (2021)

Fonte: Adaptado de Ranzani et al. (2021)

Além disso, foram trazidos os dados do CNES em fevereiro de 2020 para representar a situação do sistema de saúde (número de leitos e o número de leitos de UTI), em cada região em um momento antes da pandemia.

Já para o trabalho de Peres et al. (2021) foram considerados apenas casos com desfecho (alta ou óbito) e até a semana epidemiológica 32 de 2020 (8 de agosto de 2020), uma semana a menos que o estudo de Ranzani et al. (2021). Dessa forma, foram considerados registros de 228196 pacientes.

Com estes dados preparados, foi realizada uma análise descritiva das hospitalizações e, posteriormente, aplicado um modelo linear generalizado (regressão logística) para avaliar a associação entre os fatores sociodemográficos e a mortalidade hospitalar por COVID-19.

A Tabela 1 apresenta a distribuição da população hospitalizada por região geográfica a partir de múltiplas variáveis demográficas de acordo com o publicado em Ranzani et al. (2021). Já a Tabela 2 mostra a mortalidade hospitalar, definida como a razão entre a quantidade de óbitos e o total de casos fechados. Este indicador é calculado para o total de hospitalizações, para as que tiveram uma internação em UTI e para os pacientes que fizeram uso de ventilação mecânica invasiva.

Tabela 1 - Descrição dos pacientes hospitalizados por COVID-19 e comparação entre regiões geográficas do Brasil. Adaptado de Ranzani et al. (2021).

Características	Brasil (n=254288)	Norte (n=14712)	Nordeste (n=51993)	Centro-Oeste (n=18701)	Sudeste (n=142963)	Sul (n=25919)
Idade, média (dp) [n = 254288]	60 (17)	59 (17)	62 (18)	59 (17)	60 (17)	59 (17)
Idade mediana (1Q-3Q)	61 (47, 73)	61 (46, 73)	63 (49, 76)	59 (46, 71)	61 (47, 73)	60 (47, 72)
Faixa etária de idade, No. (%) [n =254288]						
39	34170 (13%)	2285 (15%)	6672 (13%)	2798 (15%)	18849 (13%)	3566 (14%)
49	37618 (15%)	2187 (15%)	6566 (13%)	3115 (17%)	21814 (15%)	3936 (15%)
59	47869 (19%)	2510 (17%)	8742 (17%)	3725 (20%)	27754 (19%)	5138 (20%)
69	52800 (21%)	3033 (21%)	10531 (20%)	3770 (20%)	29817 (21%)	5649 (22%)
79	44968 (18%)	2767 (19%)	10275 (20%)	3067 (16%)	24445 (17%)	4414 (17%)
Sexo masculino, No. (%) [n = 254243]	36863 (14%)	1930 (13%)	9207 (18%)	2226 (12%)	20284 (14%)	3216 (12%)
Sexo feminino, No. (%) [n = 254243]	143521 (56%)	8816 (60%)	28983 (56%)	10729 (57%)	80340 (56%)	14653 (57%)
Cor de pele, No. (%) [n = 181499]						
Branco	89374 (49%)	1340 (11%)	5515 (17%)	3322 (29%)	59502 (58%)	19695 (88%)
Preto/Pardo	88773 (49%)	10039 (86%)	26579 (81%)	7622 (67%)	42114 (41%)	2419 (11%)
Asiático	2838 (1,6%)	209 (1,8%)	611 (1,9%)	265 (2,3%)	1606 (1,6%)	147 (0,7%)
Indígena	514 (0,3%)	121 (1,0%)	95 (0,3%)	164 (1,4%)	87 (<0,1%)	47 (0,2%)
Nível de educação, No. (%) [n = 86204]						
Analfabeto	5399 (6,3%)	711 (10%)	1682 (14%)	280 (5,4%)	2250 (4,5%)	476 (4,1%)
Até o Ensino Médio	38417 (45%)	2964 (42%)	5203 (42%)	2133 (41%)	22309 (45%)	5808 (50%)
Ensino Médio	28365 (33%)	2448 (34%)	3629 (29%)	1757 (34%)	17040 (34%)	3491 (30%)
Ensino Superior	14023 (16%)	981 (14%)	1835 (15%)	1006 (19%)	8311 (17%)	1890 (16%)
Número de comorbidades [n = 90,829]						
0	14979 (16%)	788 (17%)	2794 (17%)	1654 (19%)	7803 (16%)	1940 (16%)
1-2	67610 (74%)	3458 (77%)	12088 (75%)	6199 (73%)	37051 (75%)	8814 (73%)
>= 3	8240 (10%)	271 (6%)	1221 (8%)	636 (8%)	4796 (9%)	1316 (11%)

Tabela 2 - Mortalidade hospitalar por região geográfica do Brasil e por utilização de recursos. Adaptado de Ranzani et al. (2021).

Mortalidade Hospitalar	Brasil	Norte	Nordeste	Centro-Oeste	Sudeste	Sul
Hospitalizações	87515/232036 (37,7%)	6727/13496 (49,8%)	21858/45238 (48,3%)	5964/17012 (35,1%)	45269/131556 (34,4%)	7697/24734 (31,1%)
Faixa de idade						
0-39	3780/30603 (12,4%)	393/1976 (19,9%)	1083/5587 (19,4%)	284/2498 (11,4%)	1736/17170 (10,1%)	284/3372 (8,4%)
0-49	6162/33968 (18,1%)	556/1973 (28,2%)	1542/5575 (27,7%)	504/2795 (18%)	3062/19901 (15,4%)	498/3724 (13,4%)
0-59	11818/43376 (27,2%)	945/2272 (41,6%)	2893/7461 (38,8%)	863/3373 (25,6%)	6119/25389 (24,1%)	998/4881 (20,4%)
0-69	20317/48270 (42,1%)	1662/2816 (59%)	4730/9195 (51,4%)	1380/3436 (40,2%)	10659/27453 (38,8%)	1886/5370 (35,1%)
0-79	22651/41434 (54,7%)	1784/2616 (68,2%)	5660/9086 (62,3%)	1528/2823 (54,1%)	11583/22658 (51,1%)	2096/4251 (49,3%)
0+	22787/34385 (66,3%)	1387/1843 (75,3%)	5950/8334 (71,4%)	1405/2087 (67,3%)	12110/18985 (63,8%)	1935/3136 (61,7%)
Admissão em UTI	47002/79687 (59%)	3022/3786 (79,8%)	10483/14867 (70,5%)	3734/6682 (55,9%)	24693/45224 (54,6%)	5070/9128 (55,5%)
Faixa de idade						
20-39	2225/7512 (29,6%)	195/334 (58,4%)	579/1279 (45,3%)	185/732 (25,3%)	1065/4354 (24,5%)	201/813 (24,7%)
40-49	3503/9478 (37%)	265/404 (65,6%)	799/1440 (55,5%)	324/890 (36,4%)	1763/5630 (31,3%)	352/1114 (31,6%)
50-59	6732/14034 (48%)	468/645 (72,6%)	1441/2324 (62%)	554/1266 (43,8%)	3513/8097 (43,4%)	756/1702 (44,4%)
60-69	11372/18058 (63%)	800/950 (84,2%)	2350/3318 (70,8%)	896/1420 (63,1%)	5980/10094 (59,2%)	1346/2276 (59,1%)
70-79	12257/16848 (72,8%)	779/891 (87,4%)	2720/3401 (80%)	954/1345 (70,9%)	6408/9264 (69,2%)	1396/1947 (71,7%)
80+	10913/13757 (79,3%)	515/562 (91,6%)	2594/3105 (83,5%)	821/1029 (79,8%)	5964/7785 (76,6%)	1019/1276 (79,9%)
Suporte respiratório invasivo	36046/45205 (79,7%)	2810/3155 (89,1%)	8963/10322 (86,8%)	3039/3667 (82,9%)	17325/22648 (76,5%)	3909/5413 (72,2%)
Faixa de idade						
20-39	1858/3278 (56,7%)	193/250 (77,2%)	551/791 (69,7%)	164/279 (58,8%)	774/1559 (49,6%)	176/399 (44,1%)
40-49	2850/4488 (63,5%)	269/334 (80,5%)	717/947 (75,7%)	273/397 (68,8%)	1317/2239 (58,8%)	274/571 (48%)
50-59	5459/7586 (72%)	446/520 (85,8%)	1291/1579 (81,8%)	456/605 (75,4%)	2662/3923 (67,9%)	604/959 (63%)
60-69	9028/11148 (81%)	748/821 (91,1%)	2056/2353 (87,4%)	743/875 (84,9%)	4424/5673 (78%)	1057/1426 (74,1%)
70-79	9433/10706 (88,1%)	711/765 (92,9%)	2289/2494 (91,8%)	787/863 (91,2%)	4551/5291 (86%)	1095/1293 (84,7%)
80+	7418/7999 (92,7%)	443/465 (95,3%)	2059/2158 (95,4%)	616/648 (95,1%)	3597/3963 (90,8%)	703/765 (91,9%)

A população total de pacientes tem uma média de 60 anos. A estrutura etária dos hospitalizados é mais velha no Nordeste. Nesta região, 58% dos internados têm 60 anos ou mais. Este número é de 5% a 10% maior do que nas outras regiões. Além disso, 56% dos pacientes são do sexo masculino, sem grandes variações regionais.

Em termos da cor de pele reportada, há um equilíbrio entre brancos e pretos/pardos, com cada uma representando 49% do total dos hospitalizados. No entanto, esta distribuição tem grandes diferenças entre as regiões. Enquanto pretos e pardos dominam no Norte (86%), Nordeste (81%) e Centro-Oeste (67%), os brancos são maioria destacada no Sudeste (58%) e no Sul (88%).

Para o nível de escolaridade, as regiões Norte (10%) e Nordeste (14%) apresentam uma maior quantidade de analfabetos, enquanto Sudeste (51%) e Centro-Oeste (53%) foram as regiões com pelo menos 50% dos internados com o ensino médio completo. Por fim, 90% dos pacientes no país apresentaram de zero a duas comorbidades.

Já no que diz respeito a mortalidade hospitalar, 38% dos casos com desfecho foram óbitos. Este número cresceu drasticamente conforme a população ficava mais velha, saindo de 12% para aqueles de 20 a 39 anos para 55% entre aqueles com 70 a 79 anos e 66% para aqueles com 80 anos ou mais. Para internados em UTI, a mortalidade hospitalar foi de 59%. Quando o uso de ventilação mecânica invasiva foi necessário, este valor subiu para 80%.

Esta tendência de crescimento de mortalidade hospitalar se reflete em todas as regiões. Contudo, o Norte e o Nordeste se destacam negativamente. Nelas, este indicador é consideravelmente pior do que nas outras regiões geográficas do país. Para a população hospitalizada em geral, a mortalidade é de 50% no Norte e 48% no Nordeste, enquanto varia de 31% a 35% nas outras regiões.

Também se percebe uma elevada mortalidade entre os mais jovens (20 a 39 anos) no Norte e Nordeste. Em ambas, este valor neste grupo está em 19%, o que se contrapõe com os 8% a 11% no Centro-Oeste, Sudeste e Sul. Este comportamento se reproduz tanto em internações em UTI (80% Norte, 71% Nordeste e 55% a 56% para o resto) e para os que utilizaram o suporte respiratório invasivo (89% Norte, 87% Nordeste e 83% a 72% para o resto).

Esta maior mortalidade pode estar associada com as diferenças regionais do sistema de saúde. Por mais que o país tenha uma grande quantidade de leitos, estes se encontram distribuídos de forma desigual. A Tabela 3 mostra a quantidade de leitos

totais e de UTI por 10 mil habitantes em cada região do país. Ela mostra que as regiões Norte e Nordeste, que tiveram a maior mortalidade hospitalar, também se apresentam como as regiões com menor quantidade de leitos totais e de UTI.

Tabela 3 - Quantidade de leitos totais e de UTI em fevereiro de 2020 por 10 mil habitantes por região. Adaptado de Ranzani et al. (2021).

Região	Leitos Totais por 10 mil habitantes	Leitos de UTI por 10 mil habitantes
Brasil	23,5	2,5
Norte	19,7	1,4
Nordeste	22	1,8
Centro-Oeste	25,4	2,9
Sudeste	23,9	3,1
Sul	25,9	2,3

Com o objetivo de verificar como as variáveis demográficas se associavam com a mortalidade, foi utilizado um modelo de regressão logística, conforme apresentado em Peres et al. (2021). Na formulação da construção do MLG, definida na Seção 2.2.1, considerou-se cada hospitalização como uma amostra (ou caso) e o desfecho do caso (alta ou óbito) como a variável de resposta (portanto, binária).

Foram usadas como variáveis fatores demográficos como o sexo, a faixa de idade, a cor de pele reportada, o nível de educação e a região de residência. Além disso, foram incluídas variáveis relativas a comorbidades, para ajustar a gravidade dos casos. As comorbidades consideradas foram: doenças cardiovasculares, diabetes, doenças renais, doenças neurológicas, doenças hematológicas, doenças hepáticas, obesidade, imunossupressão e doenças respiratórias crônicas.

O objetivo do modelo foi determinar se um caso teria desfecho óbito; por isso, todos os casos utilizados para treinar o modelo precisavam ter um desfecho (alta ou óbito) já definido e ter todas as variáveis sem valores faltantes. Dessa forma, foram utilizados 33413 casos. O modelo foi construído a partir da linguagem R utilizando o pacote “lme4” (Bates et al., 2015). Ele teve *Brier Score* de 0,21.

A Tabela 4 mostra os valores dos *odds ratios* de cada variável após os ajustes do modelo e o p-valor com nível de significância de 95%.

Tabela 4 - *Odds ratios* e p-valor (significância de 95%) do modelo de regressão logística para determinação do desfecho das hospitalizações. Adaptado de Peres et al. (2021).

Variável	OR (IC 95%)	p
Sexo		
Masculino	Ref.	
Feminino	0,73 (0,70 - 0,77)	<0,001
Faixa de idade		
20-39	Ref.	
40-49	1,22 (1,08 - 1,37)	<0,01
50-59	1,73 (1,55 - 1,93)	<0,001
60-69	3,05 (2,74 - 3,40)	<0,001
70-79	4,92 (4,41 - 5,50)	<0,001
80+	8,27 (7,36 - 9,30)	<0,001
Cor de pele reportada		
Branco	Ref.	
Preto/Pardo	1,15 (1,09 - 1,22)	<0,001
Asiático	1,04 (0,84 - 1,29)	0,74
Indígena	1,25 (0,73 - 2,17)	0,42
Nível de educação		
Ensino Superior	Ref.	
Ensino Médio	1,27 (1,17 - 1,39)	<0,001
Até o Ensino Médio	1,52 (1,4 - 1,65)	<0,001
Analfabeto	1,77 (1,58 - 1,98)	<0,001
Região geográfica		
Sul	Ref.	
Sudeste	1,32 (1,23 - 1,41)	<0,001
Centro-Oeste	1,24 (1,1 - 1,4)	<0,001
Nordeste	2,05 (1,86 - 2,26)	<0,001
Norte	2,76 (2,45 - 3,1)	<0,001

Os ORs evidenciam que pacientes do sexo feminino apresentam uma menor chance de morte (OR: 0,73, IC 95%: 0,70-0,77) que os do masculino e, conforme a idade dos pacientes aumenta, maior fica a chance de óbito.

Para a cor de pele reportada, a categoria de pretos e pardos foi a única significativa, para um nível de significância de 95%. Para estes pacientes, a chance de morte aumenta (OR: 1,15, IC 95%: 1,09-1,22). Ademais, quanto menor o nível de escolaridade, maior a chance de óbito.

Por fim, os ORs das regiões geográficas confirmam o que foi visto anteriormente, com pacientes das regiões Norte e Nordeste tendo uma chance de óbito consideravelmente maior do que os das outras.

Os resultados apresentados ao longo desta seção posicionam o Brasil como um país em que o sistema de saúde tem recursos distribuídos de forma desigual. Com a

chegada da pandemia, estas diferenças foram reforçadas e as regiões Norte e Nordeste mostraram índices de mortalidade hospitalar muito superiores ao restante do país.

O sistema de saúde do Brasil pode ser caracterizado como em um momento de estresse. Existe uma ampla demanda pelos recursos e algumas regiões não estão conseguindo atendê-la. Assim, surge a hipótese de que o acesso ao sistema de saúde no país está prejudicado e que isso pode impactar na mortalidade hospitalar por conta da COVID-19. Esta questão motiva o início de um novo ciclo da DSR, descrito na Seção 3.2, com o objetivo de estudar o acesso ao sistema de saúde no Brasil e sua relação com a mortalidade hospitalar.

3.2

Análise do Impacto das Condições de Acesso na Mortalidade Hospitalar

Este segundo ciclo da DSR parte da hipótese estabelecida no ciclo anterior, de que a maior mortalidade hospitalar pode estar relacionada ao acesso ao sistema de saúde. Dessa forma, este ciclo visa entender o conceito de acesso, como ele está associado com a mortalidade. Além disso, compreende um estudo quantitativo para verificar como o acesso impactou a mortalidade hospitalar por COVID-19 no Brasil ao longo do ano epidemiológico de 2020.

3.2.1

Entendimento do Negócio

Nesta seção serão apresentadas as diferentes definições para acesso ao sistema de saúde encontradas na literatura, e em particular durante as condições da pandemia da COVID-19. Em seguida, são apresentados trabalhos que analisam a correlação entre as condições de acesso e indicadores de mortalidade da população. Também foram identificadas aplicações que tratam da quantificação das condições de acesso. Por fim, busca-se elaborar uma definição de acesso que inclua os principais aspectos vistos anteriormente.

3.2.1.1

Acesso ao sistema de saúde e suas definições

Conforme Levesque, Harris e Russell (2013), o conceito de acesso à assistência médica é um ponto de foco quando o tema de sistemas de saúde entra em debate.

Todavia, a partir do que foi examinado por Daniels (1982) e corroborado por Culyer e Wagstaff (1993), este termo apresenta uma série de definições diferentes. Um dos pontos comuns de divergência diz respeito ao foco do acesso e como as características dos indivíduos se cruzam com as dos recursos.

De acordo com Goddard e Smith (2001) e Oliver (2004), o conceito de acesso a saúde é complexo. Por isso, a utilização do sistema é tomada como um indicador substituto.

Waters (2000) também define acesso como a busca e utilização do sistema de saúde por parte de um enfermo. Ele usa o conceito para realizar uma análise sobre a equidade do acesso. Já Puffer (1986) trabalha com essa visão como base para estudar se as características demográficas e socioeconômicas de um indivíduo afetam na procura pelo serviço de saúde primário.

Aday e Andersen (1974) colocam a ênfase na entrada do paciente no sistema de saúde, tratando a utilização dos recursos como o acesso em potencial. Andersen (1995) também ressalta as diferenças entre o acesso em potencial e o realizado. Enquanto o primeiro diz respeito aos recursos disponíveis, o segundo trata da utilização deles. Ele também traz variáveis demográficas, estrutura social e crenças na saúde como fatores de impacto no acesso.

Nessa mesma linha, Daniels (1982) discute que o chamado acesso em potencial pode ser tratado em termos de disponibilidade de médicos e estabelecimentos de saúde, características socioeconômicas da população e a capacidade financeira dos indivíduos, como renda e cobertura de seguros de saúde.

Um outro ponto de vista pode ser encontrado em Salkever (1976). Ele coloca os serviços de saúde como o ponto focal da avaliação do acesso ao sistema de saúde. Isto é feito ao caracterizar estes como algo que pode ser alcançado por um indivíduo que almeja o cuidado.

Existem também autores que optam por focar na dependência entre múltiplas dimensões para definir o acesso. Segundo Penchansky e Thomas (1981), as relações entre o paciente, o serviço de saúde e suas características são necessárias. Com o intuito de tornar o conceito mais preciso, trataram as dimensões de disponibilidade física e de recursos do sistema, viabilidade financeira para os usuários, acomodação dos pacientes, aceitação do serviço e acessibilidade ao local.

Já Frenk (1992) diz que o acesso deve ser visto a partir da ligação entre potenciais usuários do sistema de saúde e as características do sistema em si. O

relacionamento entre estes dois extremos da cadeia são fundamentais para uma compreensão do conceito.

Em Peters et al. (2008), a discussão de acesso passa pela interação entre usuários e serviços. Esta é caracterizada por uma relação de oferta e demanda em termos de disponibilidade física, de recursos, de profissionais e de público. Além disso, considera o aspecto financeiro tanto no que tange ao preço dos cuidados médicos quanto na capacidade da população de arcar com os custos.

Enquanto isso, Levesque, Harris e Russell (2013) definem o acesso no contexto a saúde como ter a possibilidade de identificar a necessidade de buscar cuidados médicos e usufruir deles. Dessa maneira, este pode ser traduzido de forma prática a partir dos traços socioeconômicos e demográficos da população assim como pelas características geográficas, quantidades de recursos e custos dos serviços médicos.

Assim, é possível perceber que este conceito engloba uma grande variedade de dimensões e pode ser colocado de formas distintas. Portanto, como Karikari-Martin (2010) coloca, é necessário explorar diferentes vertentes para o acesso ao sistema de saúde. Dessa maneira, será gerado um conhecimento abrangente e que pode informar a tomada de decisão.

3.2.1.2

Impacto do acesso ao sistema de saúde na mortalidade

As múltiplas barreiras a um acesso eficiente ao sistema de saúde geram uma piora perceptível nos desfechos dos casos. Logo, adotar medidas que visem mitigar os efeitos destas barreiras é de suma importância (Institute of Medicine e Millman, 1993).

Um dos desfechos que pode ser analisado é a mortalidade. Filippidis et al. (2017) associaram este indicador a dificuldades no acesso ao sistema de saúde na Grécia durante uma situação de crise. Assim, percebe-se uma relação entre o alcance dos serviços médicos com os óbitos e a barreira econômica.

Gruber, Hendren e Townsend (2014) mostraram como o investimento em difundir o acesso para cuidados médicos pode influenciar positivamente na mortalidade. O estudo tratou do caso da Tailândia após a implementação de um novo plano de saúde pública. Ele teve como resultado uma expansão do alcance dos serviços para a população mais pobre e uma consequente redução na mortalidade infantil.

Conforme Gu, Zhang e Zeng (2009) também verificaram, um acesso universal e eficiente ao sistema de saúde traz impactos significativos na expectativa de vida da população. Este resultado foi avaliado na China e se mostrou válido para países em desenvolvimento. Além disso, esta hipótese se confirma em estudos em outras localidades. É o caso da Austrália (Korda et al., 2007), da Espanha (Alonso et al., 1997) e dos Estados Unidos (Porell e Miltiades, 2001).

3.2.1.3

Acesso ao sistema de saúde e a COVID-19

Em meio a um cenário de pandemia, o acesso aos cuidados de saúde se tornou ainda mais relevante. A COVID-19 se apresenta como uma causa de estresse no sistema, especialmente em países de baixa e média renda (Mitchell e Banks, 2020). Com um volume muito elevado de pacientes, os recursos nem sempre serão o suficiente. Isso se mostra tanto no número de médicos e enfermeiros quanto na de leitos e equipamentos (Aguilera, 2020).

O desenho apresentado levanta a necessidade de focar nos fatores sociais e de conscientização do acesso. Este é o ponto levantado por Ataguba e Ataguba (2020), que discutem os determinantes sociais da saúde e ressaltam que uma comunicação eficiente dos riscos é fundamental na situação, sobretudo em países em desenvolvimento. Thakur et al. (2020) também propõem que se deve oferecer mais informação para a população sobre a doença, além de expandir a cadeia de tratamento e testagem para conter seu avanço.

Isto pode ser associado a uma série de medidas tomadas, como o isolamento social e a quarentena (Marivate e Combrink, 2020). Também existe uma alocação de recursos financeiros voltados para a testagem de potenciais contaminados e para a compra de equipamentos como os de ventilação mecânica (Cash e Patel, 2020). Assim, a COVID-19 pode ser associada a diversos desafios ligados ao acesso ao sistema de saúde.

3.2.1.4

Aplicações quantitativas para o acesso ao sistema de saúde

Medir acesso é uma missão complexa. Isto se dá porque depende de questões de naturezas diferentes. Elas podem, por exemplo, refletir variáveis geográficas,

econômicas ou cognitivas (Babazadeh et al., 2020). Além disso, conforme Sanchez e Ciconelli (2012), soma-se o fato de o conceito ser variado e complexo. Mesmo assim, existem diversas pesquisas que trabalham para associar o impacto do acesso aos cuidados e desfechos relativos a diferentes enfermidades de forma quantitativa. No entanto, isto nem sempre é feito com definições unificadas para o termo e nem com os mesmos conjuntos de variáveis.

A seguir, serão apresentados alguns estudos que trabalharam de forma quantitativa a questão do acesso ao sistema de saúde de maneira geral. Depois, o foco passará para este tipo de trabalho, mas no contexto da COVID-19.

Com o conceito de acesso definido como utilização de recursos de saúde, Whitehead et al. (1997) utilizaram grupos socioeconômicos da Inglaterra e Suécia para realizar uma regressão logística multivariada. Com base nela, os autores analisaram o impacto de variáveis como o vínculo empregatício, fatores demográficos e oferta na busca por uma consulta médica.

Socias, Koehoorn e Shoveller (2016) utilizaram dados de uma pesquisa em uma província no Canadá para verificar se o sexo do indivíduo tinha impacto no acesso ao sistema de saúde. Isto foi feito por meio de uma regressão logística que examinava se o entrevistado respondeu que não teve os cuidados médicos quando considerava necessário. As variáveis para este modelo foram faixas de idade, raça/etnia, escolaridade, se era um imigrante, renda familiar, residência urbana ou não, se existia um médico da família, se sentia pertencimento ao local e um indicador de suporte social. Dessa maneira, realizaram análises univariadas e multivariadas, cujo resultado apontou que as mulheres tinham maiores chances de não encontrarem o serviço de saúde na região.

Akinyemiju, McDonald e Lantz (2018) utilizaram dados da pesquisa da Organização Mundial de Saúde de 2003 para examinar o impacto do acesso ao sistema de saúde na triagem de pacientes para câncer cervical na África do Sul. A análise foi realizada com uma regressão logística multivariada a partir de cinco dimensões de acesso. A acessibilidade foi definida por meio de variáveis como tempo e modo de transporte. A capacidade dos indivíduos de pagar pelo cuidado foi estabelecida a partir de um indicador socioeconômico e da cobertura do seguro. Aceitação englobou o sexo do provedor e outras características do atendimento em relação ao tratamento ao paciente. A disponibilidade considerou a quantidade e o tipo de estabelecimento, além do fato de serem públicos ou privados. Por fim, a acomodação observou a habilidade

percebida dos responsáveis pelo cuidado e a qualidade de equipamentos. O estudo concluiu que a triagem para esta doença na região estava abaixo do recomendado por conta da falta de médicos e que este número precisava aumentar.

Corscadden et al. (2017) trabalharam com as dimensões de acesso definidas por Levesque, Harris e Russell (2013) para estudar como a Austrália se comparava a outros dez países em termos de cuidados primários. Para tal, basearam-se nas respostas de um questionário que envolvia oitenta perguntas relativas aos serviços de saúde e características dos indivíduos. Estas questões foram selecionadas e agrupadas em cada uma das dimensões e então avaliadas em termos das barreiras encontradas para o acesso. Também foi aplicada uma regressão logística multivariada para analisar cada barreira como variável dependente. Assim, pode-se verificar que os custos e a disponibilidade foram os mais significativos no contexto do país em relação aos outros.

Papanicolas et al. (2019) tinham como objetivo avaliar o sistema de saúde do Reino Unido frente ao de outros nove países de alta renda. Entre os pontos avaliados no trabalho estava o acesso. Para representá-lo, foram tomadas as variáveis de tempo de espera e necessidades não atendidas de cuidados médicos. Os indicadores foram retirados de uma pesquisa do sistema nacional de saúde do país e projetos similares para as outras regiões de interesse. No fim das contas, o Reino Unido não se destacou positiva nem negativamente em termos de acesso.

Alonso et al. (1997) avaliaram como a mortalidade foi afetada entre os idosos na Espanha em relação ao acesso a uma consulta médica. A pesquisa definiu casos em que os indivíduos necessitavam de assistência médica a partir do nível de saúde reportado, tinham condições crônicas ou dependiam de outra pessoa para realizar alguma função básica. Por meio desses dados, fizeram um risco relativo e modelos multivariados de regressão de Cox para associar estes fatores e outras variáveis demográficas a mortalidade.

Lefèvre et al. (2014) trabalharam com técnicas de *clustering* e modelos multinomiais para identificar grupos caracterizados a partir do uso do sistema de saúde de Paris. As características consideradas foram demográficas (idade, gênero, origem), socioeconômicas (educação, renda, *status* do seguro de saúde), posicionamentos quanto a saúde e medicina, integração social e saúde percebida. Com isso, identificaram quatro tipos de usuários do sistema de saúde, com diferentes níveis de acesso e atributos.

Dumitrache et al. (2016) examinaram as disparidades entre regiões e entre áreas rurais e urbanas em termos de profissionais de saúde na Romênia. O trabalho usa técnicas quantitativas e sistemas de informações geográficas para caracterizar como os recursos (números de médicos e de hospitais por categoria) se espalham ao longo do território e apontar as desigualdades presentes.

Wendt (2009) usou dados relacionados ao sistema de saúde para caracterizar as ofertas europeias em diferentes grupos, a partir de clusters. Os indicadores observados são gastos com o sistema de saúde, quanto do financiamento é público ou privado, quantidade de profissionais, quem tem direito ao sistema e remuneração dos profissionais. Estes dados foram coletados para quinze países e então agrupados em três *clusters*.

Já no que tange a estudos voltados para o COVID-19, a maior parte das publicações foca no excesso de mortalidade como objeto de análise.

Freitas et al. (2020) avaliaram a mortalidade semanal no Brasil por todas as causas durante o ano de 2020, até a semana epidemiológica 17, usando dados do Registro Civil para seis capitais. Então, compararam os valores com os do ano anterior. Assim, com a mortalidade esperada estimada e o intervalo de confiança de 95% projetando a mortalidade observada em 2019 para a população de 2020, calcularam o excesso de mortalidade. Este mostrou que existia um excesso de mortes e que estava altamente correlacionado com o COVID-19.

Banerjee et al. (2020) fizeram uma análise semelhante, mas no Reino Unido. As técnicas usadas foram estimativas de Kaplan-Meier e diferentes riscos relativos para definir cenários variados de mortalidade pela infecção por COVID-19. Nogueira et al. (2020) também trabalharam com este indicador de excesso com dados do começo da pandemia em Portugal.

Enquanto isso, o estudo de Moreira (2020) trabalhou a questão da disponibilidade de recursos e sua associação com os óbitos. Ele identifica as regiões de saúde do Brasil tanto com as maiores taxas de mortalidade de COVID-19 específica por doenças como respiratórias, neoplasias, cardiopatias, hipertensão e diabetes quanto as com maior escassez de UTI e ventiladores pulmonares. A partir disso, determinou um perfil de mortalidade por meio da análise de perfis latentes. Além disso, usou o método de varredura espacial para gerar clusters dos leitos e ventiladores. Dessa forma, pode cruzar os dois indicadores calculados e analisar o desempenho ao longo do território brasileiro.

3.2.1.5

Definição de um conceito de acesso unificado

Conforme visto ao longo das seções anteriores, o conceito de acesso ao sistema de saúde é complexo e múltiplo, podendo ser visualizado a partir de diferentes dimensões. Dessa forma, para fazer uma análise completa e com melhor interpretação é necessário trazer uma definição que agregue as diferentes esferas do acesso.

Com base em toda a revisão de literatura, é possível elaborar este conceito de forma semanticamente mais precisa. Portanto, para o propósito deste trabalho, o acesso será definido como: “Capacidade que o indivíduo tem de atingir e utilizar o sistema de saúde. Isto pode se manifestar por meio da viabilidade econômica e de características da população e da disponibilidade de recursos como leitos, profissionais e equipamentos nos estabelecimentos de saúde”.

Esta nova definição engloba uma série de esferas do acesso. Primeiramente, o termo “capacidade de atingir” trata da questão da demanda em potencial, que diz respeito aos casos que podem acabar necessitando de tratamento no sistema de saúde. Também diz respeito à acessibilidade no que tange a alcançar fisicamente o estabelecimento de saúde para receber cuidados médicos.

O trecho “utilizar o sistema de saúde” discute o momento em que o paciente é internado e passa a consumir recursos do hospital. Além disso, o conceito considera uma série de outros fatores externos ao ambiente médico. A viabilidade econômica pode se refletir tanto no desenvolvimento da região em que o paciente está ou no seu poder aquisitivo. As características da população abordam a estrutura demográfica do ambiente, que pode estar mais propícia para uma mortalidade mais elevada ou maior índice de contaminação, por exemplo. Por fim, as características do sistema de saúde apontam o preparo do sistema para receber a demanda. Dessa forma, considera leitos e equipamentos que poderão ser utilizados no tratamento de pacientes.

Estas esferas interagem entre si para formar uma rede de relações que influenciam no acesso e, por consequência, na mortalidade, que pode ser observada na Figura 5.

Nela, é possível ver que as características demográficas e o desenvolvimento do ambiente influenciam na demanda em potencial. Isto pode ser visualizado em fatores socioeconômicos que proporcionam melhores condições de vida para a população e

na estrutura demográfica, como por exemplo uma população mais propensa a ter um determinado tipo de comorbidade ou com idade avançada e mais suscetível à doença.

O desenvolvimento e a viabilidade econômica também são um fator de impacto para as características do sistema de saúde. Em teoria, quanto mais desenvolvido é um município, melhor é seu sistema de saúde, com mais hospitais, leitos e equipamentos.

A demanda em potencial representa todos aqueles que foram confirmados com a doença e podem necessitar de cuidados médicos. Dentro desse universo estão os indivíduos que se tornarão pacientes e, eventualmente, precisarão acessar o sistema de saúde. Enquanto isso as características do sistema de saúde representam a oferta disponível para atender tal demanda. Portanto, estas duas esferas se unem para influenciar a acessibilidade ao sistema, uma vez que é necessário ter recursos para atender os potenciais pacientes para que eles possam atingi-los.

Esta acessibilidade é o acesso físico ao hospital, ou seja, o indivíduo precisa buscar atendimento e consegui-lo. Nessas condições, conseguir chegar no sistema de saúde é o pressuposto básico para utilizá-lo. Por fim, é possível medir o impacto na mortalidade após a influência de todas as esferas anteriores.

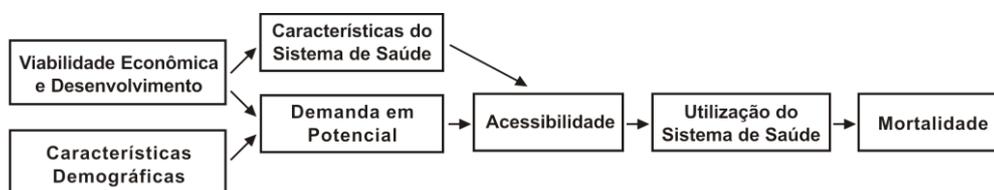


Figura 5 - Relação entre as esferas do acesso ao sistema de saúde.

Fonte: Elaboração própria

3.2.1.6

Definição da Questão de Pesquisa

A partir desse novo conceito de acesso ao sistema de saúde que engloba diferentes esferas de análise, foi possível definir uma rede de relações entre as vertentes do acesso para identificar como elas se influenciavam.

Por meio deste diagrama e de sua análise, a esfera da acessibilidade aparece como um ponto central. Ela indica o fato de o indivíduo acessar o sistema de saúde e reúne os efeitos das esferas anteriores, servindo como um resumo de todo o processo que culmina na utilização do sistema.

Isto leva a uma pergunta de pesquisa mais focada que guiará esta pesquisa. Aqui busca-se responder “qual o efeito da acessibilidade ao sistema de saúde na mortalidade?”

Para esta análise será avaliado se o paciente foi atendido em um município diferente do que reside, comparando aqueles que utilizaram o sistema de saúde em suas cidades de residência com aqueles que tiveram que se deslocar para serem internados. Este estudo envolve uma descrição das características dos pacientes hospitalizados, seguida de uma descrição dos municípios de origem destes pacientes. Estes dois níveis serão então reunidos em uma modelagem para associar o acesso com a mortalidade. No entanto, primeiro é necessário apresentar as bases de dados que serão utilizadas e o procedimento de tratamento destas bases.

Também, por motivos de clareza, é importante ressaltar que, a partir desta seção, a acessibilidade é tomada como termo sinônimo a acesso e a condição de acesso nas análises, refletindo o que foi observado no estudo sobre o conceito.

3.2.2

Entendimento dos Dados

A principal base de dados deste trabalho será a do Sistema Integrado de Vigilância Epidemiológica da Gripe (SIVEP-Gripe) (DATASUS, 2020a). Esta base é atualizada semanalmente e disponibilizada de forma pública. Ela compreende hospitalizações provenientes de Síndromes Respiratórias Agudas Graves (SRAG), entre as quais estão incluídos os casos de COVID-19. Estas internações podem ser em hospitais públicos ou privados e cada registro representa um paciente, com informações demográficas, de comorbidades e sobre seu atendimento, além dos seus municípios de residência e de internação.

A esfera de características demográficas é derivada dos dados desta base, com variáveis como idade, gênero, raça, nível de educação, comorbidades e região de residência.

A utilização do sistema de saúde também é visualizada a partir dos dados do SIVEP-Gripe. Cada registro corresponde a uma hospitalização, que equivale ao uso do sistema. Elas também armazenam dados que indicam se o paciente precisou ser internado em UTI ou se teve que utilizar ventilação mecânica (invasiva ou não-invasiva).

Para refletir a acessibilidade, o primeiro ponto observado foi uma comparação para saber se o indivíduo foi internado em seu município de residência ou não. Além disso, foi extraída a distância percorrida por cada paciente entre a cidade de residência e de internação. Isto foi feito com dados da API de matriz de distâncias do Google Maps a partir do pacote “gmapsdistance” desenvolvido por Melo, Rodriguez e Zarruk (2018) na linguagem R.

Para a dimensão de disponibilidade de recursos podem ser os dados disponíveis no Cadastro Nacional de Estabelecimentos de Saúde (CNES) (DATASUS, 2020b). A partir dele, podem ser extraídas as quantidades de leitos de UTI e enfermagem e a disponibilidade de equipamentos, como os respiradores, em um determinado mês.

No que tange à demanda em potencial, os dados desejados são relativos a casos confirmados no Brasil. Eles podem ser acessados por meio da agregação do Brasil.io (Brasil.io, 2020), um consórcio brasileiro que reúne os boletins diários das secretarias de saúde para atualizar os dados sobre a COVID-19 no país.

A viabilidade econômica e desenvolvimento é visualizada a partir de uma série de dados relativos ao município de residência do paciente. Eles são a área (IBGE, 2019), a população (IBGE, 2020a), se a cidade faz parte de uma região metropolitana (IBGE, 2020b), se é capital do estado (Prado, 2020) e o Índice de Desenvolvimento Humano Municipal (IDHM) (Atlas Brasil, 2020). O IDHM varia de 0 a 1 e aborda as perspectivas de longevidade, educação e renda no contexto de cada município brasileiro.

Finalmente, para avaliar a questão da mortalidade que será associada ao acesso ao sistema de saúde são dois indicadores observados. O primeiro é relacionado ao SIVEP-Gripe e indica se o paciente teve óbito ou alta. Já o segundo é a quantidade óbitos confirmados obtida por meio da base de dados do Brasil.io.

3.2.3

Preparação dos dados

Todas as análises deste trabalho foram realizadas usando os dados provenientes das bases descritas na seção anterior. No entanto, foi necessário algum pré-processamento para que estes dados fossem mais bem utilizados.

Para os dados do SIVEP-Gripe, a base de dados foi extraída em 8 de março de 2021 com dados que refletiam a situação da pandemia até 1º de março de 2021. Foi

realizado um procedimento de limpeza da base de dados de forma que restassem apenas casos de pacientes adultos (20 anos ou mais) hospitalizados com COVID-19 confirmado por meio do teste RT-PCR. Além disso, o período analisado foi o ano epidemiológico de 2020 e foram removidos os 30 registros que não tinham o município de residência. Dessa forma, constam dados de 456977 pacientes desde o início da pandemia no Brasil até 2 de janeiro de 2021. Todo o procedimento de definição do escopo da base para o estudo pode ser observado na Figura 6.

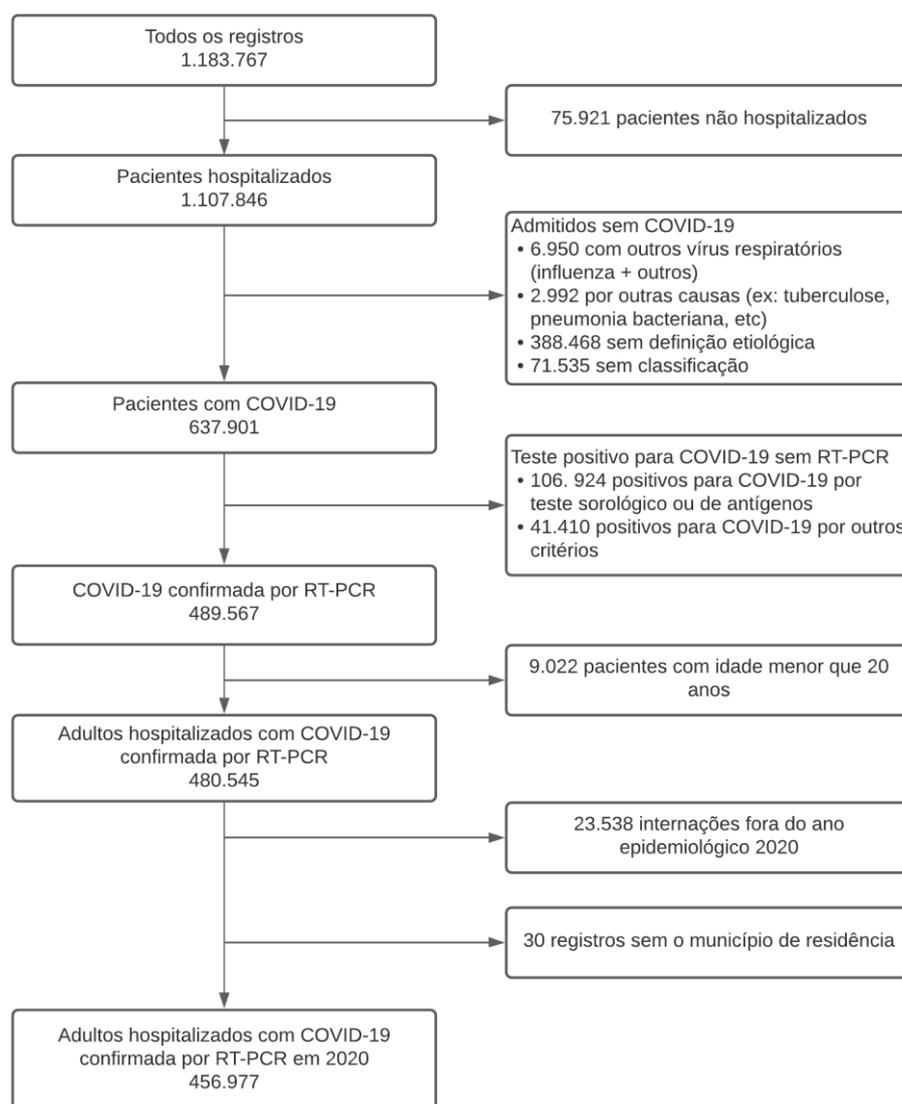


Figura 6 - Procedimento de limpeza da base SIVEP-Gripe e definição do escopo.

Fonte: Elaboração própria

Para cada um desses registros, foi mantida uma série de variáveis associadas representam fatores demográficos do paciente e características da internação. Elas podem já existir na base do SIVEP-Gripe ou terem sido criadas ou modificadas a partir

de tratamentos. A Tabela 5 mostra os tratamentos realizados para gerar as variáveis do estudo a partir dos dados do SIVEP-Gripe.

Tabela 5 - Tratamento para variáveis do SIVEP-Gripe

Variável	Tratamento
Faixas de idade	Idade em valor separada em faixas ("20-39", "40-49", "50-59", "60-69", "70-79" e "80+").
Cor de pele	Agrupamento dos valores "Preto" e "Pardo" como uma única categoria ("Preto/Pardo"), conforme apresentado em Ranzani et al. (2021).
Nível de educação	Agrupamento dos valores "Fundamental I" e "Fundamental II" como uma única categoria ("Até o Ensino Médio").
Região de residência	Determinada a partir do estado de residência do paciente.
Internação fora do município de residência	Compara o município de residência com o de internação e preenche como 1 se forem diferentes.
Número de comorbidades	Para pacientes com todas as comorbidades preenchidas, contabilizar quantas apresenta e enquadrá-lo em uma das três categorias ("0", "1-2" ou " ≥ 3 ").
Tempo de permanência no hospital	Saída do hospital – Entrada no hospital
Tempo de permanência no hospital	Saída do hospital – Entrada no hospital
Tempo de permanência na UTI	Saída da UTI – Entrada na UTI
Sintomas até admissão	Data de admissão no hospital – Data de início dos sintomas
Sintomas até admissão na UTI	Data de admissão na UTI – Data de início dos sintomas
Sintomas até óbito	Data de óbito – Data de início dos sintomas
Admissão até óbito	Data de óbito – Data de admissão no hospital

Além destas variáveis, também existem outras que não precisaram de tratamento, como o sexo, a idade, se o paciente foi para UTI, se precisou de suporte respiratório (invasivo ou não-invasivo) e o desfecho (alta ou óbito).

Para acrescentar ao trabalho com o intuito de verificar o deslocamento, foi adicionada a distância percorrida. Ela trouxe dados externos calculados a partir da matriz de distâncias do Google Maps por meio do passo-a-passo a seguir:

1 – Seleção de todos os trajetos únicos existentes entre município de residência e município de internação no SIVEP-Gripe filtrado.

2 – Utilização do pacote “gmapsdistance” na linguagem R para extrair da API do Google Maps a distância de uma viagem rodoviária entre os municípios.

3 – Para os trajetos em que não foi possível extrair um valor da API, calcular a distância euclidiana por meio da seguinte fórmula, na qual as coordenadas estão em graus e 6378137 representa o raio aproximado da Terra em metros:

$$\begin{aligned}
 \text{Distância} = & 6378137 * \arccos (\\
 & \cos (\textit{latitude origem} * \pi/180) * \cos (\textit{latitude destino} * \pi/180)) \\
 & * \cos ((\textit{longitude destino} * \pi/180) - (\textit{longitude origem} * \pi/180)) \\
 & + \textit{sen}(\textit{latitude origem} * \pi/180) * \textit{sen}(\textit{latitude destino} * \pi/180)
 \end{aligned} \tag{3.1}$$

Para a análise de municípios, foram feitos agrupamentos no SIVEP-Gripe e dados de outras bases de dados foram acrescentados. As variáveis construídas estão descritas na Tabela 6.

Tabela 6 - Descrição variáveis adicionais por município

Variável	Observações	Fonte primária
Área (Km ²)	Área dos municípios.	IBGE
População	População dos municípios.	IBGE
Densidade Demográfica	Razão entre a população e a área.	IBGE
Proporção População Brasil	Proporção da população em relação ao total da população brasileira.	IBGE
Hospitalizações	Quantidade de hospitalizações do município. Agrupamento a partir do município de residência.	SIVEP-Gripe
Hospitalizações por 100 mil	Quantidade de hospitalizações do município a cada 100 mil habitantes da cidade. Agrupamento a partir do município de residência.	SIVEP-Gripe e IBGE
Mortalidade Hospitalar	Razão entre quantidade de óbitos e quantidade de casos com desfecho (alta ou óbito).	SIVEP-Gripe
Hospitalizados que vieram de outro município	Quantidade de hospitalizados que chegaram em um município tendo uma cidade de residência diferente.	SIVEP-Gripe
Hospitalizados que foram para outro município	Quantidade de hospitalizados que saíram do município de residência para uma cidade de internação diferente.	SIVEP-Gripe

Proporção que foi hospitalizada em outro município	Proporção dos pacientes hospitalizados de um município que foram internados em uma cidade diferente.	SIVEP-Gripe
Óbitos hospitalizados por 100 mil	Quantidade de óbitos de pacientes hospitalizados a cada 100 mil habitantes do município.	SIVEP-Gripe e IBGE
Óbitos em outro município por 100 mil	Quantidade de óbitos de pacientes hospitalizados que foram para outra cidade a cada 100 mil habitantes do município.	SIVEP-Gripe e IBGE
Óbitos no mesmo município por 100 mil	Quantidade de óbitos de pacientes hospitalizados que ficaram na cidade a cada 100 mil habitantes do município.	SIVEP-Gripe e IBGE
Distância média percorrida por indivíduos que saíram do município	Distância média em quilômetros do deslocamento de quem sai do município para ser internado em outra cidade. Calculado a partir do agrupamento do município de residência.	SIVEP-Gripe e Google Maps
Casos totais por 100 mil	Quantidade total de casos confirmados a cada 100 mil habitantes do município em 02 de janeiro de 2021.	Brasil.io e IBGE
Óbitos totais por 100 mil	Quantidade total de óbitos confirmados a cada 100 mil habitantes do município em 02 de janeiro de 2021.	Brasil.io e IBGE
IDHM	Índice de desenvolvimento humano do município.	Atlas Brasil
Leitos por 10 mil	Agrupamento da quantidade total de leitos disponíveis no município por meio do registro do CNES. Este valor é tratado para representar quantos leitos existem a cada 10 mil habitantes da cidade.	CNES e IBGE
Leitos de UTI por 10 mil	Agrupamento da quantidade total de leitos de UTI disponíveis no município por meio do registro do CNES. Este valor é tratado para representar quantos leitos de UTI existem a cada 10 mil habitantes da cidade.	CNES e IBGE

Além disso, para analisar as dinâmicas de deslocamento dos pacientes ao longo do território brasileiro, foi criada uma classificação para cada tipo de município com base no fato de ser uma capital ou parte de uma região metropolitana (RM ou região integrada de desenvolvimento econômico (RIDE)). Esta definição pode ser encontrada na Tabela 7.

Tabela 7 - Definição da classificação de municípios

Classificação	Explicação
Capital	Municípios que são capitais dos estados.
Periferia das capitais	Municípios que englobam a RM ou RIDE associada à capital do estado. Campo Grande (MS) e Rio Branco (AC) não fazem parte de nenhuma RM ou RIDE. As capitais não estão inclusas nesta classificação.
Outras RMs	Municípios que englobam as RMs ou RIDEs que não estão associadas às capitais dos estados.
Interior	Municípios que não fazem parte de nenhuma RM ou RIDE.

O Apêndice I apresenta o mapa do Brasil colorido conforme a classificação de cada município conforme as categorias definidas na Tabela 7.

As RMs e RIDEs consideradas como associadas às capitais de cada estado são apresentadas na Tabela 8.

Tabela 8 - RM ou RIDE associada a cada capital

Capital	Estado	RM/RIDE
Aracaju	SE	Região Metropolitana de Aracaju
Belém	PA	Região Metropolitana de Belém
Belo Horizonte	MG	Região Metropolitana de Belo Horizonte
Boa Vista	RR	Região Metropolitana da Capital
Brasília	DF	Região Integrada de Desenvolvimento do Distrito Federal e Entorno
Campo Grande	MS	-
Cuiabá	MT	Região Metropolitana do Vale do Rio Cuiabá
Curitiba	PR	Região Metropolitana de Curitiba
Florianópolis	SC	Região Metropolitana de Florianópolis
Fortaleza	CE	Região Metropolitana de Fortaleza
Goiânia	GO	Região Metropolitana de Goiânia
João Pessoa	PB	Região Metropolitana de João Pessoa
Macapá	AP	Região Metropolitana de Macapá
Maceió	AL	Região Metropolitana de Maceió
Manaus	AM	Região Metropolitana de Manaus
Natal	RN	Região Metropolitana de Natal

Palmas	TO	Região Metropolitana de Palmas
Porto Alegre	RS	Região Metropolitana de Porto Alegre
Porto Velho	RO	Região Metropolitana de Porto Velho
Recife	PE	Região Metropolitana de Recife
Rio Branco	AC	-
Rio de Janeiro	RJ	Região Metropolitana do Rio de Janeiro
Salvador	BA	Região Metropolitana de Salvador
São Luís	MA	Região Metropolitana da Grande São Luís
São Paulo	SP	Região Metropolitana de São Paulo
Teresina	PI	Região Integrada de Desenvolvimento da Grande Teresina
Vitória	ES	Região Metropolitana da Grande Vitória

3.2.4

Modelagem e Avaliação

Com as bases de dados já obtidas e tratadas, é possível finalmente analisar a questão de pesquisa para responder como a acessibilidade impacta na mortalidade por COVID-19 no Brasil. Este estudo será dividido em três partes. Na primeira, serão avaliadas as características dos pacientes hospitalizados. A segunda trata de aspectos dos municípios brasileiros que tiveram pacientes infectados e hospitalizados. Por fim, é feita uma análise a partir de um modelo linear de efeitos mistos para verificar as conclusões e identificar o impacto da acessibilidade na mortalidade.

3.2.4.1

Descrição dos pacientes hospitalizados

Por meio da base de dados do SIVEP-Gripe extraída e tratada conforme as seções anteriores apresentaram, esta primeira parte do estudo tem como objetivo descrever a população hospitalizada por COVID-19 no Brasil. Para tal, apresenta dados de 456.977 internações no período de 26 de fevereiro de 2020 a 02 de janeiro de 2021, o que representa as internações que atendem os critérios descritos na Seção 3. Com o objetivo de analisar a questão da acessibilidade, a Tabela 9 exhibe o cenário descritivo desta amostra e diferencia entre aqueles que foram internados no município de residência e os que tiveram que se deslocar para outra cidade.

A Tabela 9 mostra que pacientes que foram internados em um município diferente daquele em que moram totalizaram 26% das internações. A amostra se distribui de forma regular entre as diferentes faixas de idade, com prevalência dos internados entre 60 e 69 anos. Foram 21% de todos os hospitalizados, sendo 21% dos que foram internados no município de residência e 22% dos que precisaram se deslocar para outra cidade.

Homens compuseram 56% das hospitalizações. A maior parte dos hospitalizados se declarou como branca (54%), com pretos ou pardos em número um pouco menor (44-45%). Em termos de nível de educação, destacaram-se aqueles que tinham chegado até o ensino médio. Estes totalizaram 45% do total, 43% dos internados no município de residência e 48% dos que tiveram que ir para outra cidade.

Por volta de 90% dos hospitalizados, que tinham todos os campos de comorbidades preenchidos na base, apresentavam até duas comorbidades. Já em termos de deslocamento, para aqueles que foram internados em municípios diferentes do que residiam, a mediana da distância percorrida foi de 35 quilômetros (1º quartil: 20 Km; 3º quartil: 74 Km).

Até aqui não parece existir muita diferença na estrutura demográfica dos pacientes internados em seus municípios de residência e os que tiveram que se deslocar para outras cidades. Quando se avalia a região de residência, no entanto, a Tabela 9 mostra alguma variação na distribuição de hospitalizações ao longo do território brasileiro. Entre todos os pacientes internados no próprio município de residência, 56% estavam na região Sudeste, enquanto nas regiões Nordeste e Sul estes números são 15% e 14%, respectivamente. Quando se fala dos internados que tiveram que se deslocar para outros municípios, o Sudeste era a região do município de residência de 50% destes pacientes. Já o Nordeste e o Sul representam 21% e 19% delas, respectivamente.

Tabela 9 - Descrição dos pacientes hospitalizados por COVID-19 e comparação entre internações no município de residência e fora

Características	Total (n = 456977)	Internação	
		No Município de Residência (n = 337403, 74%)	Fora do Município de Residência (n = 119574, 26%)
Idade, No. (%) [n = 456977]			
média (dp)	61 (17)	61 (17)	60 (17)
mediana (1Q-3Q)	62 (48, 73)	62 (49, 74)	61 (48, 73)

Faixa de idade,			
No. (%) [n = 456977]			
20-39	57193 (13%)	41846 (12%)	15347 (13%)
40-49	64918 (14%)	47679 (14%)	17239 (14%)
50-59	85656 (19%)	62564 (19%)	23092 (19%)
60-69	98152 (21%)	72079 (21%)	26073 (22%)
70-79	84083 (18%)	62046 (18%)	22037 (18%)
80+	66975 (15%)	51189 (15%)	15786 (13%)
Sexo,			
No. (%) [n = 456916]			
Masculino	256309 (56%)	187759 (56%)	68550 (57%)
Feminino	200607 (44%)	149603 (44%)	51004 (43%)
Cor de pele,			
No. (%) [n = 347653]			
Branco	187192 (54%)	137178 (54%)	50014 (54%)
Preto/Pardo	154657 (44%)	114414 (45%)	40243 (44%)
Asiático	4949 (1,4%)	3734 (1,5%)	1215 (1,3%)
Indígena	855 (0,2%)	535 (0,2%)	320 (0,3%)
Nível de educação,			
No. (%) [n = 159657]			
Analfabeto	9511 (6,0%)	6561 (5,6%)	2950 (6,9%)
Até o Ensino Médio	71131 (45%)	50723 (43%)	20408 (48%)
Ensino Médio	51569 (32%)	38441 (33%)	13128 (31%)
Ensino Superior	27446 (17%)	21216 (18%)	6230 (15%)
Região de residência,			
No. (%) [n = 456977]			
Norte	21259 (4,7%)	17206 (5,1%)	4053 (3,4%)
Nordeste	75182 (16%)	50287 (15%)	24895 (21%)
Centro-Oeste	39553 (8,7%)	31951 (9,5%)	7602 (6,4%)
Sudeste	249131 (55%)	189125 (56%)	60006 (50%)
Sul	71852 (16%)	48834 (14%)	23018 (19%)
Número de comorbidades,			
No. (%) [n = 174546]			
Nenhuma	27576 (16%)	20092 (16%)	7484 (16%)
1-2	130428 (75%)	96050 (75%)	34378 (74%)
>=3	16542 (9,5%)	12008 (9,4%)	4534 (9,8%)
Distância Percorrida (Km), mediana (1Q-3Q) [n = 456977]			
	-	-	35 (20, 74)

Quando se compara a situação em que os pacientes foram internados em seus municípios de residência com a situação em que tiveram que se deslocar para outras cidades, percebe-se que a diferença entre as proporções da região Sudeste e as das regiões Nordeste e Sul diminuiu. Ela saiu de 27% (56% - 29%) no caso daqueles internados na própria cidade de origem e passou para 10% (50% - 40%) quando se considera aqueles que se foram hospitalizados em outras localidades. Isto chama a

atenção para a questão regional, na perspectiva geográfica. Dessa forma, a Tabela 10 mostra o percentual de internações realizadas em um município diferente em cada região geográfica de residência.

Tabela 10 - Proporção de internações fora do município de residência por região do Brasil

<u>Região de residência</u>	<u>% Deslocamentos</u>
Brasil	26,2%
Norte	19,1%
Nordeste	33,1%
Centro-Oeste	19,2%
Sudeste	24,1%
Sul	32,0%

No Brasil, foram 26,2% de pacientes hospitalizados que se deslocaram de suas cidades de residência em direção a outros municípios. Todavia, os números indicam que nas regiões Nordeste (33,1%) e Sul (32%) os pacientes precisaram se deslocar para outros municípios em busca de cuidado médico com mais frequência do que no restante do país. Isto reforça a mensagem de disparidades regionais e mostra que este é um ponto a ser observado mais a fundo posteriormente.

Além disso, os dados do SIVEP-Gripe podem ser usados para avaliar a utilização de recursos, como utilização de suporte respiratório e de UTI, e desfechos e tempos relacionados à internação.

A Tabela 11 traz estas agregações, diferenciando entre aqueles que foram internados no município de origem e os que tiveram que se deslocar.

Uma das principais observações provenientes da Tabela 11 é de que, entre aqueles que se deslocam em busca da internação, é mais comum o paciente dar entrada na UTI (47%) ou fazer uso de ventilação mecânica invasiva (26%) do que para os que ficaram no município de habitação (36% e 20%, respectivamente). Isto indica que, em geral, indivíduos que se deslocam apresentam casos mais graves. Infelizmente, como não existe a data do deslocamento ou uma data de transferência na base do SIVEP-Gripe disponibilizada pelo Ministério da Saúde, não é possível saber o momento do deslocamento, o que poderia indicar se os pacientes tiveram que sair do seu município de origem por causa da ausência de recursos (após a internação) ou se foi em busca de um melhor acesso ao sistema de saúde (antes da internação).

No que diz respeito aos tempos de permanência ou o transcorrido entre sintomas e diversos marcos da internação, o comportamento não teve diferenças entre os grupos.

Apenas o tempo total desde os primeiros sintomas até o óbito apresentou uma pequena variação mais perceptível, com indivíduos que precisaram se deslocar tendo um tempo total de 17 dias (1º quartil: 10, 3º quartil: 26) e aqueles que não saíram do município de residência ficando internados por 16 dias (1º quartil: 9, 3º quartil: 25).

Tabela 11 - Tempos e desfechos diferenciados por internação no município de residência e fora

Características	Total	Internação	
		No Município de Residência	Fora do Município de Residência
Admissão na UTI [n = 379809]			
Não	230669 (61%)	178041 (64%)	52628 (53%)
Sim	149140 (39%)	102033 (36%)	47107 (47%)
Suporte respiratório [n = 363949]			
Não	93503 (26%)	72036 (27%)	21467 (23%)
Sim, não invasivo	192296 (53%)	143843 (53%)	48453 (51%)
Sim, invasivo	78150 (21%)	53477 (20%)	24673 (26%)
Local de ventilação não-invasiva [n = 184162]			
Fora da UTI	127048 (69%)	97823 (71%)	29225 (62%)
Na UTI	57114 (31%)	39425 (29%)	17689 (38%)
Local de ventilação invasiva [n = 76400]			
Fora da UTI	9247 (12%)	7257 (14%)	1990 (8,2%)
Na UTI	67153 (88%)	44896 (86%)	22257 (92%)
Mortalidade hospitalar [n = 419246]			
	147107 (35%)	105897 (34%)	41210 (38%)
Tempo de permanência (dias), mediana (1Q-3Q)			
No hospital [n = 402988]	8 (4, 15)	8 (4, 14)	8 (5, 15)
Na UTI [n = 87053]	8 (4, 15)	8 (4, 15)	8 (4, 15)
Tempos (dias), mediana (1Q-3Q)			
Sintomas até admissão [n = 375885]	7 (4, 10)	7 (4, 9)	7 (4, 10)
Sintomas até admissão na UTI [n = 136023]	7 (4, 10)	7 (4, 10)	7 (4, 11)
Sintomas até óbito [n = 145705]	16 (10, 25)	16 (9, 25)	17 (10, 26)
Admissão até óbito [n = 139781]	11 (5, 19)	10 (5, 19)	11 (6, 19)

Por fim, a amostra geral traz uma mortalidade hospitalar de 35%. Este valor cai para 34% (105897/310322) quando se trata apenas dos indivíduos hospitalizados no município de residência, mas sobe para 38% (41210/108924) para aqueles que

precisam deixar suas cidades de origem. Vale indicar que para o cálculo dessa mortalidade foram considerados apenas casos encerrados, ou seja, com uma classificação de alta ou óbito. Esta comparação também pode ser vista na Figura 7.

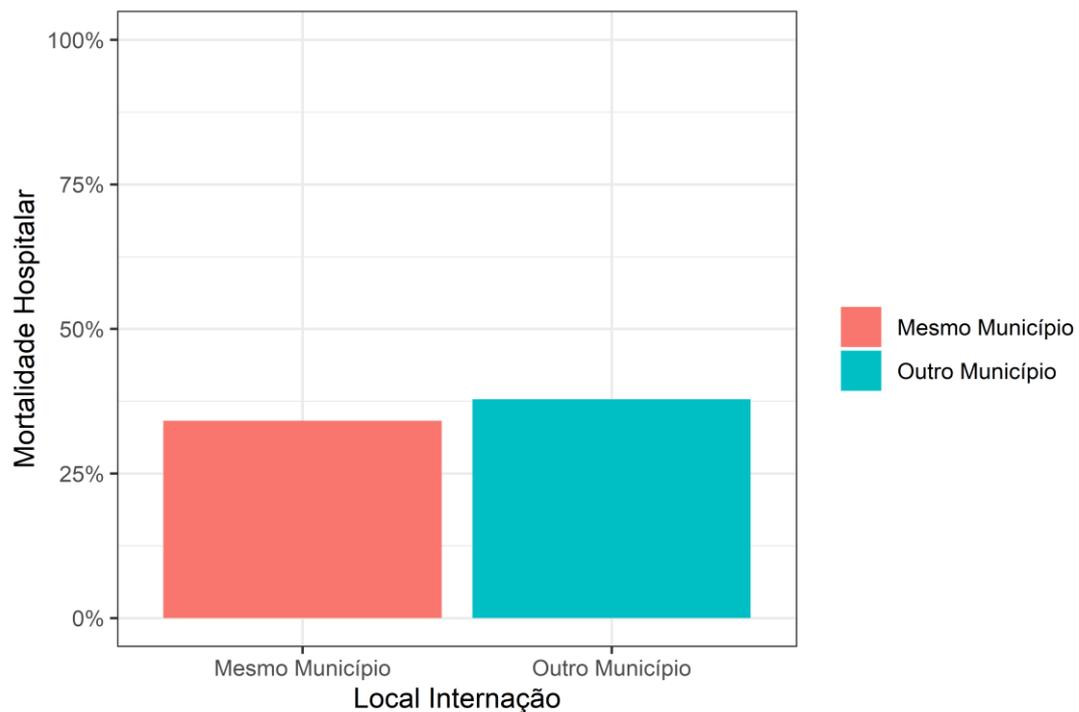


Figura 7 - Mortalidade hospitalar para internados no município de residência ou em outro município.

Fonte: Elaboração própria

Além disso, a questão da mortalidade pode ser analisada por outras perspectivas demográficas. As Figuras 8 e 9 apresentam a mortalidade hospitalar a partir da comparação entre os internados na cidade de residência e os que precisaram se deslocar, para cada um dos possíveis valores das variáveis demográficas observadas. Em todas elas verifica-se a tendência de uma maior mortalidade para aqueles que saíram do município de origem em direção a outras cidades.

O Apêndice II apresenta os dados que alimentaram as figuras.

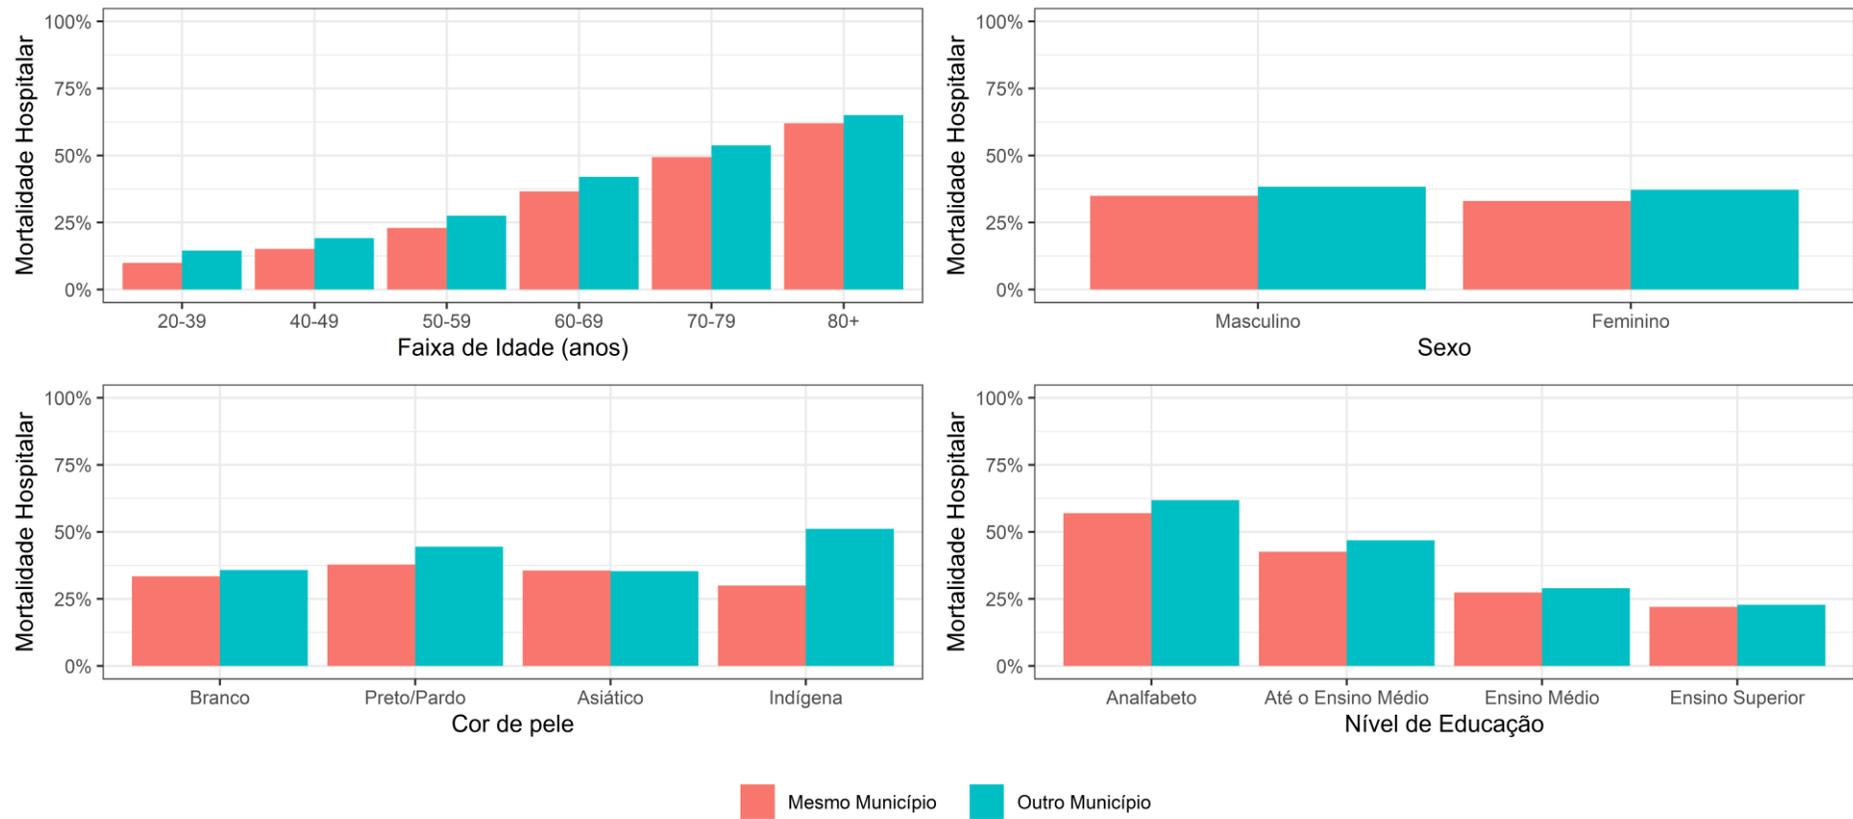


Figura 8 - Mortalidade hospitalar comparando internados no mesmo município de residência e em outro município, por faixa de idade, sexo, cor de pele e nível de educação

Fonte: Elaboração própria

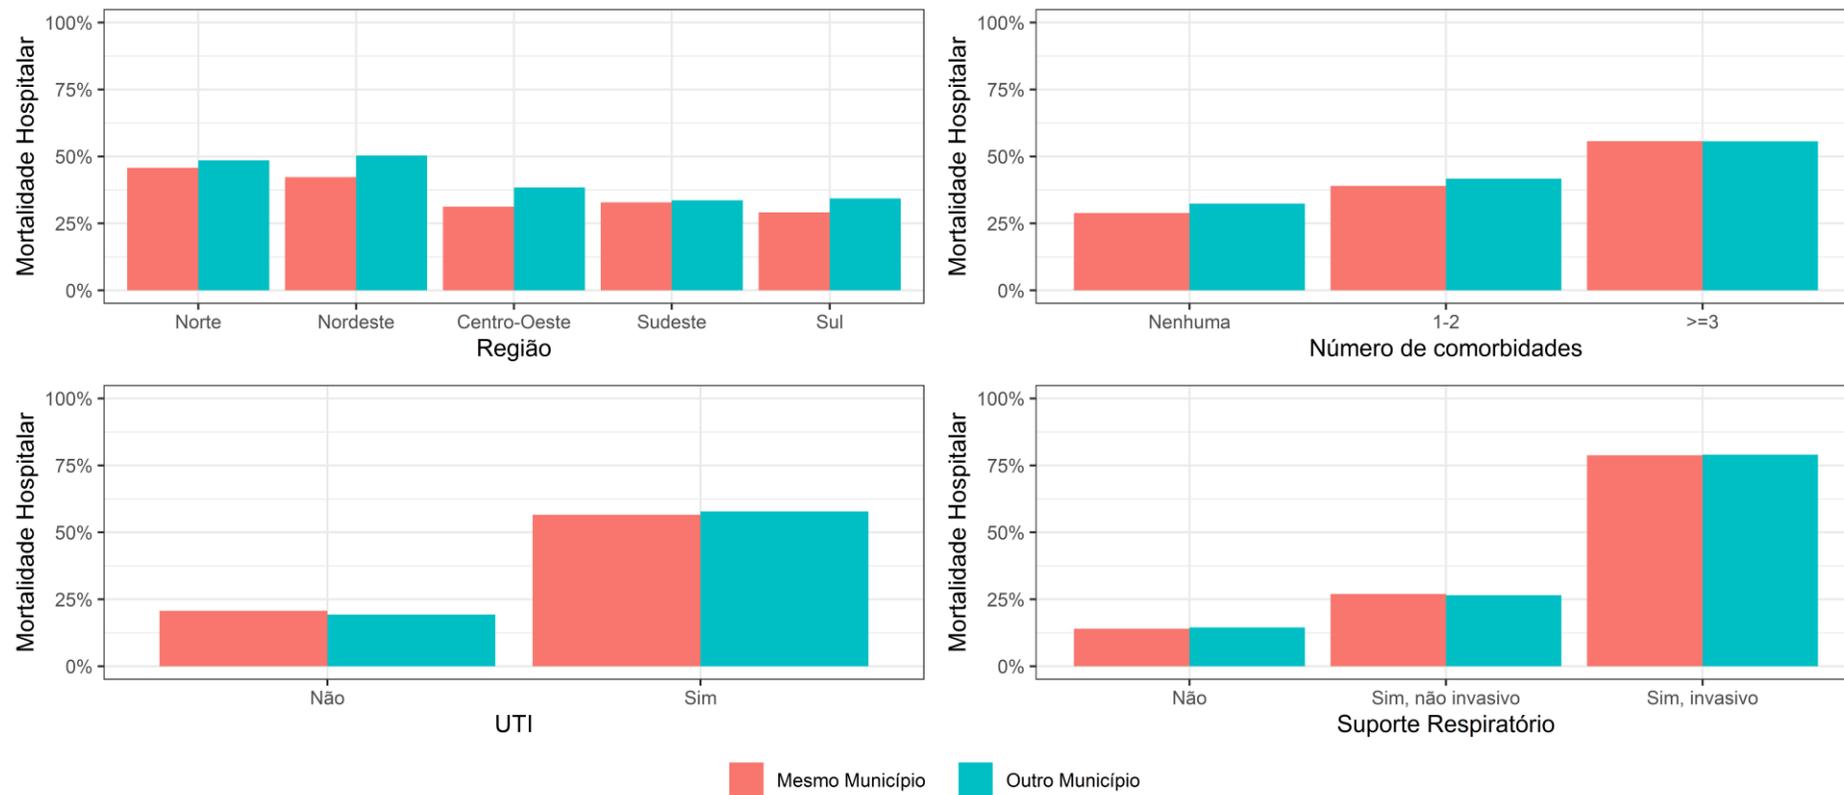


Figura 9 - Mortalidade hospitalar comparando internados no município de residência e fora por região de residência, número de comorbidades, internação em UTI e uso de suporte respiratório

Fonte: Elaboração própria

Como a questão regional foi um dos pontos de destaque tanto no primeiro ciclo da DSR, ao analisarmos os casos dos pacientes a partir das internações no município de residência ou fora dele, coube investigar este ponto mais a fundo.

Portanto, a ideia foi agrupar municípios em situações de condições socioeconômicas similares. Para isso, conforme descrito na seção anterior, foram usadas as informações sobre capitais de estados e composição de regiões metropolitanas (RM) para elaborar uma categorização para cada cidade. Dessa forma, esta categorização agrupa os municípios diferenciando-os entre capitais, periferia das capitais (municípios de regiões metropolitanas associadas às capitais), outras RMs (municípios de regiões metropolitanas não associadas às capitais) e interior (o restante, ou seja, municípios que não são capitais nem integram regiões metropolitanas).

A Tabela 12 apresenta a distribuição demográfica da população hospitalizada considerando a categorização do município de residência dos pacientes. Assim, pode-se analisar como estas diferentes divisões podem influenciar na dinâmica de acesso.

Tabela 12 - Descrição dos pacientes hospitalizados por COVID-19 e comparação a partir da classificação do município de residência

Características	Total (n = 456977)	Município de residência			
		Capital (n = 185489, 41%)	Periferia das capitais (n = 92461, 20%)	Outras RMs (n = 63368, 14%)	Interior (n = 115659, 25%)
Internações fora do município, No. [n = 456977]	119574	7800	50429	18879	42466
Idade, No. (%) [n = 456977]					
média (dp)	61 (17)	61 (17)	60 (17)	61 (17)	61 (17)
mediana (1Q-3Q)	62 (48, 73)	62 (49, 74)	61 (48, 72)	62 (49, 73)	62 (49, 74)
Faixa de idade, No. (%) [n = 456977]					
20-39	57193 (13%)	23021 (12%)	12098 (13%)	7721 (12%)	14353 (12%)
40-49	64918 (14%)	26170 (14%)	14047 (15%)	9039 (14%)	15662 (14%)
50-59	85656 (19%)	34080 (18%)	17803 (19%)	12221 (19%)	21552 (19%)
60-69	98152 (21%)	39465 (21%)	20423 (22%)	13819 (22%)	24445 (21%)

70-79	84083 (18%)	34099 (18%)	16362 (18%)	11587 (18%)	22035 (19%)
80+	66975 (15%)	28654 (15%)	11728 (13%)	8981 (14%)	17612 (15%)
Sexo, No. (%) [n = 456916]					
Masculino	256309 (56%)	103340 (56%)	51420 (56%)	36079 (57%)	65470 (57%)
Feminino	200607 (44%)	82126 (44%)	41027 (44%)	27277 (43%)	50177 (43%)
Cor de pele, No. (%) [n = 347653]					
Branco	187192 (54%)	56288 (45%)	35251 (52%)	39492 (73%)	56161 (55%)
Preto/Pardo	154657 (44%)	65163 (53%)	31572 (46%)	13863 (26%)	44059 (43%)
Asiático	4949 (1,4%)	2304 (1,9%)	1037 (1,5%)	556 (1,0%)	1052 (1,0%)
Indígena	855 (0,2%)	198 (0,2%)	109 (0,2%)	50 (<0,1%)	498 (0,5%)
Nível de educação, No. (%) [n = 159657]					
Analfabeto	9511 (6,0%)	2357 (4,8%)	1787 (6,1%)	1229 (4,4%)	4138 (7,8%)
Até o Ensino Médio	71131 (45%)	19094 (39%)	13647 (46%)	12716 (46%)	25674 (48%)
Ensino Médio	51569 (32%)	16844 (34%)	10225 (35%)	8992 (32%)	15508 (29%)
Ensino Superior	27446 (17%)	11005 (22%)	3756 (13%)	4996 (18%)	7689 (15%)
Região de residência, No. (%) [n = 456977]					
Norte	21259 (4,7%)	11357 (6,1%)	1934 (2,1%)	751 (1,2%)	7217 (6,2%)
Nordeste	75182 (16%)	36436 (20%)	10993 (12%)	4887 (7,7%)	22866 (20%)
Centro-Oeste	39553 (8,7%)	24056 (13%)	5119 (5,5%)	0 (0%)	10378 (9,0%)
Sudeste	249131 (55%)	97302 (52%)	59946 (65%)	35338 (56%)	56545 (49%)
Sul	71852 (16%)	16338 (8,8%)	14469 (16%)	22392 (35%)	18653 (16%)
Número de comorbidades, No. (%) [n = 174546]					
Nenhuma	27576 (16%)	9395 (15%)	4705 (16%)	4498 (16%)	8978 (17%)
1-2	130428 (75%)	45759 (74%)	22361 (75%)	21910 (76%)	40398 (75%)

>=3	16542 (9,5%)	6546 (11%)	2623 (8,8%)	2603 (9,0%)	4770 (8,8%)
Distância Percorrida (Km), mediana (1Q- 3Q) [n = 456977]	0 (0, 8)	0 (0, 0)	9 (0, 27)	0 (0, 13)	0 (0, 46)

As capitais representam os grandes centros do país, como São Paulo e Rio de Janeiro. Nelas estão concentradas a maior proporção dos casos (41%) entre as quatro classificações. Além disso, delas saem poucos pacientes (7800) em direção a outras cidades.

Todas as classificações apresentam distribuições semelhantes entre as faixas etárias, de pacientes do sexo masculino e feminino e por quantidade de comorbidades. Já em termos de cor de pele reportada, nas capitais reside uma população hospitalizada majoritariamente preta ou parda (53%). Isso se opõe às outras classificações, que têm maioria branca. As outras RMs têm a maior disparidade, residindo 73% de internados brancos e 26% pretos ou pardos.

No que tange ao nível de educação, internados que residem nas capitais completaram pelo menos o ensino médio em 56% dos casos. Esse número é superior aos 49% do total do Brasil, 48% da periferia das capitais, 50% das outras RMs e 44% do interior.

Para as regiões de residência, a Sudeste é a que abriga a maior parte das internações em todas as classificações. Os valores variam de 65% na periferia das capitais até 49% no interior. A região Nordeste foi a segunda que mais teve internações entre as capitais (20%) e no interior (20%). Já a região Sul ficou como a segunda colocada entre as cidades da periferia das capitais (16%) e das outras RMs (35%).

Também chama a atenção o fato de que não existe internação em municípios da categoria “Outras RMs” no Centro-Oeste. No entanto, isto é explicado por não existir nenhuma RM ou RIDE nesta região geográfica que não esteja vinculada às capitais dos estados.

Por fim, para a distância percorrida, a única categoria com mediana diferente de zero foi a periferia das capitais. Nela, o deslocamento mediano foi de 9 Km (1º quartil: 0 Km, 3º quartil: 27 Km). Isto indica que moradores dos municípios das periferias das capitais precisam sair de suas residências para buscar tratamento em outras localidades.

Esta conclusão é corroborada pela Tabela 13, que mostra a proporção de atendimentos fora do município de residência que acontecem para pacientes provenientes de municípios de cada categoria. Ela mostra, por exemplo, que os internados que residem em cidades da periferia das capitais são internados em outras cidades em 55% das situações. Este é o maior valor entre as classificações por grande margem e o único em que mais da metade dos pacientes precisam se deslocar.

Tabela 13 - Proporção de pacientes hospitalizados fora do município de residência por classificação

Classificação do município de residência	% Internações fora do município de residência
Brasil	26%
Capital	4%
Periferia das capitais	55%
Outras RMs	30%
Interior	37%

No entanto, ainda é possível entender melhor quais são os principais trajetos entre essas categorias no Brasil. Dessa forma, com o intuito de visualizar como se comportam os movimentos ao longo do território brasileiro, a Tabela 14 apresenta a quantidade de deslocamentos entre os municípios das diferentes categorias. Nela, os percentuais indicam a proporção de internações daquele trajeto em relação ao total de deslocamentos saindo daquela categoria.

Tabela 14 - Matriz de deslocamentos entre o município de residência e o município de internação.

Residência	Internação				Casos com deslocamento	Casos sem deslocamento
	Capital	Periferia das capitais	Outras RMs	Interior		
Capital	666 (8,5%)	6422 (82%)	196 (2,5%)	516 (6,6%)	7800	177689
Periferia das capitais	33733 (67%)	15391 (31%)	244 (0,5%)	1061 (2,1%)	50429	42032
Outras RMs	2362 (13%)	435 (2,3%)	15338 (81%)	744 (3,9%)	18879	44489
Interior	11982 (28%)	2204 (5,2%)	2173 (5,1%)	26107 (61%)	42466	73193

Ao analisar o grupo das capitais estaduais, observa-se que ocorrem menos deslocamentos no período analisado, apesar do maior número de internações. Além disso, 82% dos deslocamentos saindo de alguma capital têm como destino uma cidade

classificada como periferia das capitais, mas mesmo este número não é representativo (5%) sobre o total de deslocamentos no Brasil.

Alguns deslocamentos de destaque são entre municípios das RMs não vinculadas às capitais (81%) e entre cidades do interior (61%), o que indica a existência de demandas por hospitais em centros regionais, que estão mais distantes das capitais, e nem sempre podem ir em direção aos maiores municípios dos estados. Para aqueles que saem do interior, as capitais também são um destino relevante (28%).

Contudo, o trajeto de volume mais significativo está daqueles que saem da periferia das capitais em direção às capitais. Este representa 67% de todas as saídas dessa categoria e 28% de todos os deslocamentos do Brasil. Portanto, essa transição fica marcada como uma movimentação de interesse e que pode ser estudada mais a fundo.

Para reforçar o poder de atração das capitais, a Tabela 15 mostra o percentual do total de deslocamentos em direção aos municípios de cada uma das categorias. Nela, as capitais se colocam como a categoria que mais recebe pacientes de cidades distintas (41%).

Tabela 15 - Deslocamentos chegando em cada categoria de município

Classificação Município	Internação	% Total Chegadas
Capital		41%
Periferia das capitais		20%
Outras RMs		15%
Interior		24%

Uma análise mais profunda e que avalia o comportamento dos trajetos entre categorias de município saindo de cada região geográfica do Brasil está no Apêndice III. Ele enfatiza a mensagem de que os trajetos saindo de municípios da periferia das capitais em direção às capitais são os principais, uma vez que esse tipo de deslocamento é o mais volumoso em todas as regiões, menos a Norte, na qual é o segundo maior.

3.2.4.2

Descrição dos municípios de origem

A seção anterior caracterizou os pacientes internados por COVID-19 no Brasil no ano epidemiológico de 2020 e trouxe informações relativas ao município em que foram internados e às condições do caso. Agora, os dados serão mais agregados e tratarão dos municípios em que tais pacientes residiam. Assim, esta seção tem como intenção mostrar as características das cidades conforme as classificações definidas a priori. Este estudo tem como intuito buscar explicações para os movimentos encontrados na análise por pacientes, descritos na Seção 3.2.4.1.

A Tabela 16 traz valores relativos aos municípios que tiveram pelo menos um residente internado (seja na própria cidade ou em outra) por COVID-19 no ano epidemiológico de 2020. Os dados tratam da população, da infraestrutura do sistema de saúde e das hospitalizações, casos e óbitos. Cada dado é relativo às classificações dos municípios. Por exemplo, a área de 97726,56 Km² é o total das áreas somadas das capitais.

Tabela 16 - Descrição das características dos municípios a partir da classificação

Características	Capital	Periferia das capitais	Outras RMs	Interior
Total de municípios	27	398	859	3846
Área (Km ²)	96726,56	476343,10	481403,31	6786184,53
População	50534555	39175612	29763301	89109767
Densidade demográfica	522,45	82,24	61,83	13,13
Proporção população brasileira	24%	19%	14%	42%
Hospitalizações	185489	92461	63368	115659
Hospitalizações por 100 mil	367,05	236,02	212,91	129,79
Mortalidade hospitalar residentes	31,1%	33,8%	30,6%	33,6%
Hospitalizados que vieram de outro município	48743	24452	17951	28423
Hospitalizados que foram para outro município	7800	50429	18879	42466
Proporção que foi hospitalizada em outro município	4,2%	54,5%	29,8%	36,7%
Óbitos hospitalizados por 100 mil	114,09	79,83	65,05	43,56
Óbitos em outro município por 100 mil	4,92	41,92	20,50	18,18
Óbitos no mesmo município por 100 mil	109,17	37,91	44,55	25,38
Leitos por 10 mil	25,98	10,97	16,14	14,74
Leitos de UTI por 10 mil	3,78	1,27	1,58	1,00

Apesar de conter apenas 27 municípios, o grupo de capitais abriga 24% da população brasileira, com uma densidade demográfica mais de seis vezes maior que a periferia das capitais, que é a categoria com segundo maior valor no quesito. As capitais também são o grupo com mais hospitalizações, tanto em números absolutos (185489) quanto por 100 mil habitantes (367,05). Elas são os centros que recebem maior quantidade de pacientes de outros municípios (48743) e são a categoria da qual menos internados saem (7800).

Por terem um maior número de internações, as capitais também são as com maior número de óbitos de pacientes hospitalizados por 100 habitantes (114,09) mesmo sem ter a maior taxa de mortalidade hospitalar de pacientes residentes – 31,1%, abaixo da periferia das capitais e do interior. Além disso, é a categoria que abriga a maior parte dos recursos, com as maiores taxas de leitos totais e de UTI por 10 mil habitantes, sendo 25,98 e 3,78, respectivamente.

A periferia das capitais, cujo deslocamento de pacientes para as capitais foi apontado como um destaque na seção anterior, também está em evidência aqui. Ela aparece com a segunda maior quantidade de hospitalizações por 100 mil habitantes (236,02) e a maior mortalidade hospitalar de pacientes residentes (33,8%). Também é a categoria com maior proporção de deslocamentos em busca de internação (54,5%), segunda maior quantidade de óbitos hospitalares por 100 mil habitantes (79,83) e a única em que mais habitantes morreram após se deslocar do que no próprio município de residência. Por fim, tem o sistema de saúde de recursos mais escasso, com a menor oferta de leitos totais por 10 mil habitantes (10,97) e a segunda menor de leitos de UTI por 10 mil habitantes (1,27).

Corroborando para a mensagem de maior mortalidade na periferia das capitais, a Tabela 17 traz a mortalidade hospitalar dos internados em cada uma das categorias.

Tabela 17 - Mortalidade hospitalar dos internados em cada categoria

Classificação	Mortalidade Hospitalar Internados
Capital	31,7%
Periferia das capitais	35,0%
Outras RMs	30,7%
Interior	32,4%

Nela, percebe-se que 35% daqueles que foram hospitalizados na periferia das capitais, faleceram. Este índice pode ajudar a explicar o porquê de um fluxo elevado dos pacientes de municípios desta classificação em direção às capitais, que têm uma taxa menor (31,7%).

Como forma alternativa de analisar as características dos municípios, o Apêndice IV apresenta as variáveis em termos de mediana, primeiro quartil e terceiro quartil.

Por fim, com o objetivo de analisar as relações entre as variáveis a nível de município, a Figura 10 traz uma matriz de correlações calculadas a partir do método de Spearman. Nela, os termos “mesmo” e “fora” tratam se a internação aconteceu no município de residência do paciente ou em uma outra cidade. Os valores das correlações estão no Apêndice V.

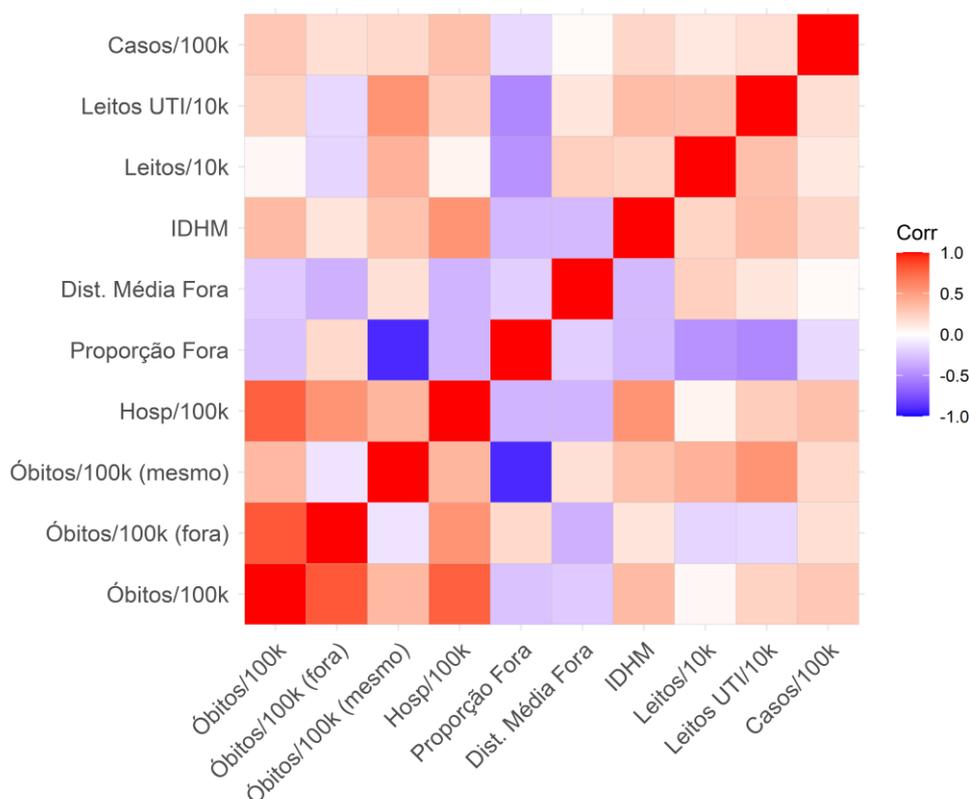


Figura 10 - Matriz de correlações a nível de município

Fonte: Elaboração própria

Aqui, destaca-se a forte correlação negativa entre a proporção de pacientes saindo do município e a quantidade de leitos de UTI por 10 mil habitantes. Essa relação representa que quanto maior a estrutura do sistema de saúde da cidade, menor será a evasão em busca de tratamentos em outras localidades.

3.2.4.3

Associação entre acessibilidade e mortalidade

As seções anteriores mostraram as características dos pacientes hospitalizados, suas características e deslocamentos. Também apresentaram os atributos dos municípios para melhor descrever como a acessibilidade ao sistema de saúde se manifestou no Brasil durante o período da pandemia em 2020. Esta análise leva a uma avaliação da associação entre acessibilidade e a mortalidade.

Como é o caso em todo este capítulo, a acessibilidade é avaliada a partir da variável que diz se a internação ocorreu no município de residência do paciente. Para avaliar este impacto na mortalidade e controlar seu efeito a partir de outras características da internação, mas também levando em consideração o fato regional na perspectiva geográfica, foi desenvolvido um modelo de regressão logística de efeitos mistos, conforme definido na Seção 2.2.2.

A Tabela 18 mostra as variáveis consideradas como efeitos fixos no modelo.

Tabela 18 - Efeitos fixos do modelo

Variável	Observação
Faixa de idade	Usada para ajustar pelas características e condições do paciente.
Sexo	Usada para ajustar pelas características e condições do paciente.
Internação fora do município de residência	Usada para representar a acessibilidade.
Número de comorbidades	Usada para ajustar pelas características e condições do paciente.
Classificação do município	Usada para representar as condições do ambiente do paciente.

Já no que diz respeito ao efeito aleatório, a região de residência (que denominamos aqui de região geográfica) foi a variável escolhida. Esta decisão foi motivada pelo trabalho de Ranzani et al. (2021) e pelas conclusões apresentadas até agora no estudo. Elas mostraram um impacto do fator regional entre as diferentes partes do país. Como citado anteriormente, modelos de efeitos mistos são mais eficientes quando o efeito aleatório tem pelo menos cinco níveis (Bolker et al., 2009). Por isso, escolheu-se a região de residência ao invés da classificação do município.

Também não foi utilizado o município, uma vez que existem muitos municípios com uma quantidade pequena de hospitalizações, o que pode prejudicar os resultados do modelo.

Na formulação da construção do MLGM, considerou-se cada hospitalização como uma amostra (ou caso), e o desfecho do caso (alta ou óbito) como a variável de resposta (portanto, binária). O objetivo do modelo foi determinar se um caso teria desfecho óbito, e todos os casos utilizados para treinar o modelo precisavam ter um desfecho (alta ou óbito) já definido e ter todas as variáveis sem valores faltantes. Desta forma, foram eliminados todos os casos que tinham variáveis faltantes, restando 163337 registros. O modelo foi construído a partir da linguagem R utilizando o pacote “lme4” (Bates et al., 2015).

Ele teve *Brier Score* de 0,21. Este valor está abaixo de 0,25, que corresponderia a um modelo que prevê probabilidade de 0,5 para todas as observações. Desta forma, é melhor que um modelo aleatório. Este índice também é comparável ao apresentado por Peres et al. (2021) em um modelo de propósito semelhante.

A Tabela 19 mostra os valores dos *odds ratios* de cada variável após os ajustes do modelo e o p-valor com nível de significância de 95%.

Tabela 19 - *Odds ratios* e p-valor (significância de 95%) do modelo de efeitos mistos para determinação do desfecho das hospitalizações

Variável	Efeito Aleatório: Região geográfica	
	OR (IC 95%)	P
Faixa de Idade		
20-39	Ref.	
40-49	1,22 (1,15-1,29)	p < 0,001
50-59	1,64 (1,55-1,73)	p < 0,001
60-69	2,82 (2,68-2,97)	p < 0,001
70-79	4,51 (4,28-4,75)	p < 0,001
80+	7,57 (7,18-7,98)	p < 0,001
Número de Comorbidades		
0	Ref.	
1-2	1,33 (1,29-1,37)	p < 0,001
>=3	2,51 (2,4-2,62)	p < 0,001
Sexo		
Masculino	Ref.	
Feminino	0,77 (0,76-0,79)	p < 0,001
Internação fora do município de residência		
Não	Ref.	
Sim	1,10 (1,07-1,12)	p < 0,001

Classificação Município Residência	Ref.	
Capital		
Periferia das capitais	1,28 (1,24-1,33)	p < 0,001
Outras RMs	1,09 (1,06-1,13)	p < 0,001
Interior	1,09 (1,06-1,12)	p < 0,001

O primeiro ponto a se destacar é que todas as variáveis se apresentaram significantes, ou seja, com nível de significância de 95% mesmo após os ajustes. No que tange às idades e comorbidades, a conclusão natural é a esperada, de que quanto mais idade e mais comorbidades o paciente tem, maior a chance de óbito. Pacientes do sexo feminino (OR: 0,77, IC 95%: 0,76-0,79) apresentam chances menores de morrer em comparação aos do sexo masculino.

Em termos da classificação do município, foram confirmados os achados de seções anteriores. Pacientes da periferia das capitais apresentam maior chance de óbito (OR: 1,28, IC 95%: 1,24-1,33). Além disso, as outras categorias fora da capital (outras RMs e interior) também têm chances de óbito superiores a ela. Isto ajuda a justificar o deslocamento da periferia das capitais em direção à capital e, em menor escala, também as saídas das outras RMs e do interior para as grandes cidades.

Ao reunir os números da Tabela 19 com a escassez de recursos constatada na periferia das capitais (vide Tabela 16), tem-se o cenário completo em que moradores da periferia das capitais saem em busca de atendimento médico nas capitais. Com um estresse de sistema caracterizado pela quantidade elevada de casos hospitalizados e falta de recursos que levam a uma alta mortalidade, tem-se a necessidade de buscar condições melhores para receber cuidados médicos.

Neste contexto, caracterizam-se as capitais como o principal grupo de cidades do Brasil, nas quais estão concentradas cerca de um quarto da população brasileira em um espaço geográfico reduzido (1,1% da área geográfica total do país), o que leva a uma densidade demográfica díspar. Por serem municípios mais densos em termos populacionais, também são as localidades com maior quantidade de casos. As capitais já apresentam uma quantidade elevada de casos, que eventualmente se tornam hospitalizações. Como a rede de recursos de saúde está concentrada nos grandes centros, estes recebem um grande volume de pacientes vindo de outras regiões. Todavia, conforme a Tabela 19, a chance de óbito para aqueles que foram internados em um município diferente daquele em que residem é maior (OR: 1,10, IC 95%: 1,07-1,12), o que mostra que estes movimentos nem sempre têm o efeito desejado.

Isto corrobora um panorama em que cerca de 26% dos pacientes precisam se deslocar em busca de internação (Tabelas 9 e 10) e muitas vezes encontram sistemas de saúde sobrecarregados, com pacientes em estado grave e falta de recursos de UTI (Tabela 11). Tais fatores caracterizam um prejuízo no acesso ao sistema de saúde no Brasil, e têm como consequência uma mortalidade hospitalar elevada durante a condição de pandemia no país, corroborando a hipótese desta pesquisa.

4 Conclusões

Esta dissertação teve como objetivo principal caracterizar o que é acesso ao sistema de saúde e avaliar como ele impacta na mortalidade hospitalar. Isto foi feito com foco no cenário da pandemia da COVID-19 no Brasil ao longo do ano epidemiológico de 2020. Para isso, foi utilizada a metodologia científica da *Design Science Research*, com dois ciclos iterativos.

No primeiro deles, foi elaborado um panorama da pandemia no Brasil até meados de agosto de 2020. Nele se destacaram disparidades regionais, que levaram a hipótese de que o sistema de saúde não está distribuído de forma igual no país e que este fator poderia impactar a mortalidade em decorrência da COVID-19. Tal hipótese motivou, portanto, a realização do 2º ciclo DSR.

No segundo ciclo, a intenção foi identificar como o acesso se associou à mortalidade. Para isso, foi necessário entender este conceito, que se mostrou variado e complexo. Dessa forma, a partir de diversas referências, foi elaborado um conceito próprio e preciso, englobando múltiplas esferas de acesso.

Para converter esta definição em uma análise quantitativa foi examinada a esfera da acessibilidade e associada à mortalidade hospitalar. Assim, dados do SIVEP-Gripe foram usados para avaliar a população hospitalizada por COVID-19 no Brasil ao longo do ano epidemiológico de 2020.

Esta análise mostrou que 26% dos brasileiros hospitalizados no período tiveram que sair de seus municípios de residência em direção a outros. Também ficou marcada a prevalência de casos mais graves, com maior admissão em UTI e uso de suporte respiratório para estes pacientes deslocados. A mensagem das disparidades regionais se manteve e, com o intuito de analisar estas dinâmicas mais a fundo, foram definidas categorias para os municípios do país com base nas capitais e regiões metropolitanas.

Este estudo mostrou um deslocamento destacado das periferias das capitais em direção às capitais. Estas periferias apresentaram uma alta mortalidade hospitalar e recursos mais limitados no sistema de saúde. Assim, mais da metade dos pacientes dessa categoria de município foram motivados a buscar outra cidade para atendimento.

As capitais receberam a maior parte desses casos, muito provavelmente por serem as opções com maior oferta de leitos.

Estes pacientes que se deslocaram tiveram mortalidade elevada, com maior chance de óbito do que os que ficaram nos municípios de residência. Isto foi mostrado a partir de um modelo de regressão de efeitos mistos e levou ao fato de que o acesso e, mais especificamente, a acessibilidade ao sistema de saúde são fundamentais para reduzir o impacto da mortalidade. Todavia, como o Brasil se apresentou com um sistema com elevado grau de estresse por conta da quantidade de casos e da falta de recursos, esta acessibilidade foi prejudicada e levou a uma mortalidade elevada por conta da COVID-19 no país ao longo de 2020.

Os resultados apresentados podem influenciar o governo em tomadas de decisão. Isto se aplica principalmente ao mostrar a necessidade de uma melhor distribuição de recursos nos sistemas de saúde nas periferias das capitais, o que aliviaria a pressão na rede das capitais.

Como sugestão de trabalhos futuros, podem ser usadas outras estratégias para modelar o acesso. Abordagens bayesianas e grafos acíclicos dirigidos são técnicas com potencial para serem testadas em estudos com objetivo semelhante. Outra opção é focar em técnicas de clusterização para observar como diferentes municípios se agrupam como forma de avaliar outras classificações.

5

Referências Bibliográficas

ADAY, L. A.; ANDERSEN, R. A framework for the study of access to medical care. **Health Services Research**, v. 9, n. 3, p. 208–220, 1974.

AGUILERA, B. Ethical allocation of scarce health care resources in the context of the COVID-19 crisis. **Medwave**, v. 20, n. 05, p. e7935–e7935, 15 jun. 2020.

AKEN, J. E. VAN. Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules: Paradigm of the Design Sciences. **Journal of Management Studies**, v. 41, n. 2, p. 219–246, 10 fev. 2004.

AKINYEMIJU, T. F.; MCDONALD, J. A.; LANTZ, P. M. Health care access dimensions and cervical cancer screening in South Africa: analysis of the world health survey. **BMC Public Health**, v. 15, n. 1, p. 382, dez. 2015.

ALONSO, J. et al. Unmet health care needs and mortality among Spanish elderly. **American Journal of Public Health**, v. 87, n. 3, p. 365–370, mar. 1997.

ANDERSEN, R. M. Revisiting the behavioral model and access to medical care: does it matter? **Journal of Health and Social Behavior**, v. 36, n. 1, p. 1–10, mar. 1995.

ANDRADE, C. Understanding Relative Risk, Odds Ratio, and Related Terms: As Simple as It Can Get: (Clinical and Practical Psychopharmacology). **The Journal of Clinical Psychiatry**, v. 76, n. 07, p. e857–e861, 22 jul. 2015.

ATAGUBA, O. A.; ATAGUBA, J. E. Social determinants of health: the role of effective communication in the COVID-19 pandemic in developing countries. **Global Health Action**, v. 13, n. 1, p. 1788263, 31 dez. 2020.

ATLAS BRASIL. **Atlas do Desenvolvimento Humano no Brasil: Índice de Desenvolvimento Humano Municipal**. Disponível em: <<http://www.atlasbrasil.org.br/2013/pt/download/base/>>. Acesso em: 21 ago. 2020.

ATUN, R. et al. Health-system reform and universal health coverage in Latin America. **The Lancet**, v. 385, n. 9974, p. 1230–1247, mar. 2015.

BABAZADEH, S. et al. The influence of health facility-level access measures on modern contraceptive use in Kinshasa, DRC. **PLOS ONE**, v. 15, n. 7, p. e0236018, 23 jul. 2020.

BANERJEE, A. et al. Estimating excess 1-year mortality associated with the COVID-19 pandemic according to underlying conditions and age: a population-based cohort study. **The Lancet**, v. 395, n. 10238, p. 1715–1725, maio 2020.

BATES, D. et al. Fitting Linear Mixed-Effects Models Using **lme4**. **Journal of Statistical Software**, v. 67, n. 1, 2015.

BOLKER, B. M. et al. Generalized linear mixed models: a practical guide for ecology and evolution. **Trends in Ecology & Evolution**, v. 24, n. 3, p. 127–135, mar. 2009.

BRASIL.IO. **ESPECIAL COVID-19 - Dados por Município**. Disponível em: <<https://brasil.io/covid19/>>. Acesso em: 22 mar. 2021.

BRESLOW, N. E.; CLAYTON, D. G. Approximate Inference in Generalized Linear Mixed Models. **Journal of the American Statistical Association**, v. 88, n. 421, p. 9–25, mar. 1993.

BRIER, G. W. Verification Forecast Expressed in Terms of Probability. **Monthly Weather Review**, v. 78, n. 1, 15 abr. 1950.

CANDIDO, D. S. et al. Evolution and epidemic spread of SARS-CoV-2 in Brazil. **Science**, v. 369, n. 6508, p. 1255–1260, 4 set. 2020.

CASH, R.; PATEL, V. Has COVID-19 subverted global health? **The Lancet**, v. 395, n. 10238, p. 1687–1688, maio 2020.

CHEN, N. et al. Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study. **The Lancet**, v. 395, n. 10223, p. 507–513, fev. 2020.

CORSCADDEN, L. et al. Barriers to accessing primary health care: comparing Australian experiences internationally. **Australian Journal of Primary Health**, v. 23, n. 3, p. 223, 2017.

CULYER, A. J.; WAGSTAFF, A. Equity and equality in health and health care. **Journal of Health Economics**, v. 12, n. 4, p. 431–457, dez. 1993.

DANIELS, N. Equity of Access to Health Care: Some Conceptual and Ethical Issues. **The Milbank Memorial Fund Quarterly. Health and Society**, v. 60, n. 1, p. 51, 1982.

DATASUS. **CNES - Cadastro Nacional de Estabelecimentos de Saúde**. Disponível em: <<http://cnes.datasus.gov.br/pages/downloads/arquivosBaseDados.jsp>>. Acesso em: 21 ago. 2020b.

DATASUS. **SRAG 2020 - Banco de Dados de Síndrome Respiratória Aguda Grave - incluindo dados da COVID-19**. Disponível em: <<https://shiny.hmg.saude.gov.br/tr/dataset/bd-srag-2020>>. Acesso em: 8 mar. 2021a.

DE SOUZA, W. M. et al. Epidemiological and clinical characteristics of the COVID-19 epidemic in Brazil. **Nature Human Behaviour**, v. 4, n. 8, p. 856–865, ago. 2020.

DUMITRACHE, L. et al. Contrasting Clustering in Health Care Provision in Romania: Spatial and Aspatial Limitations. **Procedia Environmental Sciences**, v. 32, p. 290–299, 2016.

FARAWAY, J. J. **Extending the linear model with R: generalized linear, mixed effects and nonparametric regression models**. 1. ed. Boca Raton: Chapman & Hall/CRC, 2006.

FILIPPIDIS, F. T. et al. Medium-term impact of the economic crisis on mortality, health-related behaviours and access to healthcare in Greece. **Scientific Reports**, v. 7, n. 1, p. 46423, jun. 2017.

FOSSO WAMBA, S. et al. How ‘big data’ can make big impact: Findings from a systematic review and a longitudinal case study. **International Journal of Production Economics**, v. 165, p. 234–246, jul. 2015.

FREITAS, A. R. R. et al. Tracking excess deaths associated with the COVID-19 epidemic as an epidemiological surveillance strategy-preliminary results of the evaluation of six Brazilian capitals. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 53, p. e20200558, 2020.

FRENK, J. The concept and measurement of accessibility. In: WHITE, K. et al. (Eds.). **Health services research: an anthology**. Washington, D.C: Pan American Health Organization, Pan American Sanitary Bureau, Regional Office of the World Health Organization, 1992. p. 842–855.

GELMAN, A. Analysis of variance—why it is more important than ever. **The Annals of Statistics**, v. 33, n. 1, 1 fev. 2005.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GODDARD, M.; SMITH, P. Equity of access to health care services: theory and evidence from the UK. **Social Science & Medicine**, v. 53, n. 9, p. 1149–1162, nov. 2001.

GRUBER, J.; HENDREN, N.; TOWNSEND, R. M. The Great Equalizer: Health Care Access and Infant Mortality in Thailand. **American Economic Journal: Applied Economics**, v. 6, n. 1, p. 91–107, 1 jan. 2014.

GU, D.; ZHANG, Z.; ZENG, Y. Access to healthcare services makes a difference in healthy longevity among older Chinese adults. **Social Science & Medicine**, v. 68, n. 2, p. 210–219, jan. 2009.

GUMBRECHT, J.; HOWARD, J. **WHO declares novel coronavirus outbreak a pandemic**. Disponível em: <<https://edition.cnn.com/2020/03/11/health/coronavirus-pandemic-world-health-organization/index.html>>. Acesso em: 20 ago. 2020.

HARAPAN, H. et al. Coronavirus disease 2019 (COVID-19): A literature review. **Journal of Infection and Public Health**, v. 13, n. 5, p. 667–673, maio 2020.

HEVNER et al. Design Science in Information Systems Research. **MIS Quarterly**, v. 28, n. 1, p. 75, 2004.

HEVNER, A. A Three Cycle View of Design Science Research. **Scandinavian Journal of Information Systems**, v. 19, 1 jan. 2007.

HUANG, C. et al. Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. **The Lancet**, v. 395, n. 10223, p. 497–506, fev. 2020.

HUBBARD, A. E. et al. To GEE or Not to GEE: Comparing Population Average and Mixed Models for Estimating the Associations Between Neighborhood Risk Factors and Health. **Epidemiology**, v. 21, n. 4, p. 467–474, jul. 2010.

IBGE. **Áreas Territoriais 2019**. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15761-areas-dos-municipios.html?=&t=acesso-ao-produto>>. Acesso em: 8 nov. 2020.

IBGE. **Estimativas da População 2020**. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html?=&t=downloads>>. Acesso em: 20 out. 2020a.

IBGE. **Regiões Metropolitanas, Aglomerações Urbanas e Regiões Integradas de Desenvolvimento**. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura->

territorial/18354-regioes-metropolitanas-aglomeracoes-urbanas-e-regioes-integradas-de-desenvolvimento.html?=&t=downloads>. Acesso em: 25 jan. 2021b.

INSTITUTE OF MEDICINE (U.S.); MILLMAN, M. L. (EDS.). **Access to health care in America**. Washington, D.C: National Academy Press, 1993.

KARIKARI-MARTIN, P. Use of Healthcare Access Models to Inform the Patient Protection and Affordable Care Act. **Policy, Politics, & Nursing Practice**, v. 11, n. 4, p. 286–293, nov. 2010.

KORDA, R. J. et al. Differential impacts of health care in Australia: trend analysis of socioeconomic inequalities in avoidable mortality. **International Journal of Epidemiology**, v. 36, n. 1, p. 157–165, 1 fev. 2007.

LACERDA, D. P. et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741–761, 26 nov. 2013.

LANDMANN-SZWARCWALD, C.; MACINKO, J. A panorama of health inequalities in Brazil. **International Journal for Equity in Health**, v. 15, n. 1, p. 174, s12939- 016- 0462–1, dez. 2016.

LEFÈVRE, T. et al. Applying Multivariate Clustering Techniques to Health Data: The 4 Types of Healthcare Utilization in the Paris Metropolitan Area. **PLoS ONE**, v. 9, n. 12, p. e115064, 15 dez. 2014.

LEVESQUE, J.-F.; HARRIS, M. F.; RUSSELL, G. Patient-centred access to health care: conceptualising access at the interface of health systems and populations. **International journal for equity in health**, v. 12, p. 18–18, 11 mar. 2013.

LU, H.; STRATTON, C. W.; TANG, Y. Outbreak of pneumonia of unknown etiology in Wuhan, China: The mystery and the miracle. **Journal of Medical Virology**, v. 92, n. 4, p. 401–402, abr. 2020.

MAGEZI, D. A. Linear mixed-effects models for within-participant psychology experiments: an introductory tutorial and free, graphical user interface (LMMgui). **Frontiers in Psychology**, v. 6, p. 2, 22 jan. 2015.

MARINHO, F. et al. Burden of disease in Brazil, 1990–2016: a systematic subnational analysis for the Global Burden of Disease Study 2016. **The Lancet**, v. 392, n. 10149, p. 760–775, set. 2018.

MARIVATE, V.; COMBRINK, H. M. Use of Available Data To Inform The COVID-19 Outbreak in South Africa: A Case Study. **Data Science Journal**, v. 19, p. 19, 6 maio 2020.

MCCULLAGH, P.; NELDER, J. A. **Generalized linear models**. 2. ed. Boca Raton: Chapman & Hall/CRC, 1998.

MELO, R. A.; RODRIGUEZ, D.; ZARRUK, D. **Distance and Travel Time Between Two Points from Google Maps**. Disponível em: <<https://github.com/rodazuero/gmapsdistance>>. Acesso em: 12 jan. 2021.

MENNI, C. et al. Real-time tracking of self-reported symptoms to predict potential COVID-19. **Nature Medicine**, v. 26, n. 7, p. 1037–1040, jul. 2020.

MIGUEL, P. A. C. Estudo de caso na engenharia de produção: estruturação e recomendações para sua condução. **Production**, v. 17, n. 1, p. 216–229, abr. 2007.

MITCHELL, R.; BANKS, C. Emergency departments and the COVID-19 pandemic: making the most of limited resources. **Emergency medicine journal: EMJ**, v. 37, n. 5, p. 258–259, 2020.

MOREIRA, R. DA S. COVID-19: unidades de terapia intensiva, ventiladores mecânicos e perfis latentes de mortalidade associados à letalidade no Brasil. **Cadernos de Saúde Pública**, v. 36, n. 5, p. e00080020, 2020.

MS. **Painel Coronavírus**. Disponível em: <<https://covid.saude.gov.br/>>. Acesso em: 9 abr. 2021.

MS. **Brasil confirma primeiro caso da doença**. Disponível em: <<https://www.saude.gov.br/noticias/agencia-saude/46435-brasil-confirma-primeiro-caso-de-novo-coronavirus>>. Acesso em: 3 ago. 2020.

MULLACHERY, P.; SILVER, D.; MACINKO, J. Changes in health care inequity in Brazil between 2008 and 2013. **International Journal for Equity in Health**, v. 15, n. 1, p. 140, dez. 2016.

NELDER, J. A.; WEDDERBURN, R. W. M. Generalized Linear Models. **Journal of the Royal Statistical Society. Series A (General)**, v. 135, n. 3, p. 370, 1972.

OBERG, A. L.; MAHONEY, D. W. Linear Mixed Effects Models. In: AMBROSIUS, W. T. (Ed.). **Topics in Biostatistics**. Methods in Molecular Biology. Totowa, NJ: Humana Press, 2007. v. 404p. 213–234.

OLIVER, A. Equity of access to health care: outlining the foundations for action. **Journal of Epidemiology & Community Health**, v. 58, n. 8, p. 655–658, 1 ago. 2004.

PAPANICOLAS, I. et al. Performance of UK National Health Service compared with other high income countries: observational study. **BMJ**, p. 16326, 27 nov. 2019.

PENCHANSKY, R.; THOMAS, J. W. The Concept of Access: Definition and Relationship to Consumer Satisfaction. **Medical Care**, v. 19, n. 2, p. 127–140, fev. 1981.

PERES, I. T. et al. Sociodemographic factors associated with COVID-19 in-hospital mortality in Brazil. **Public Health**, v. 192, p. 15–20, mar. 2021.

PÉREZ, A. M. **Machine Learning to Predict High-cost Hospitalizations**. Dissertação (mestrado)—Rio de Janeiro: Pontifícia Universidade Católica - Rio de Janeiro, 2020.

PETERS, D. H. et al. Poverty and Access to Health Care in Developing Countries. **Annals of the New York Academy of Sciences**, v. 1136, n. 1, p. 161–171, 25 jul. 2008.

PORELL, F. W.; MILTIADES, H. B. Access to Care and Functional Status Change Among Aged Medicare Beneficiaries. **The Journals of Gerontology Series B: Psychological Sciences and Social Sciences**, v. 56, n. 2, p. S69–S83, 1 mar. 2001.

PRADO, K. **Municípios Brasileiros**. Disponível em: <<https://github.com/kelvins/Municipios-Brasileiros>>. Acesso em: 25 jan. 2021.

PUFFER, F. Access to Primary Health Care: A Comparison of the US and the UK. **Journal of Social Policy**, v. 15, n. 3, p. 293–313, jul. 1986.

QUENÉ, H.; VAN DEN BERGH, H. Examples of mixed-effects modeling with crossed random effects and with binomial data. **Journal of Memory and Language**, v. 59, n. 4, p. 413–425, nov. 2008.

RANZANI, O. T. et al. Characterisation of the first 250 000 hospital admissions for COVID-19 in Brazil: a retrospective analysis of nationwide data. **The Lancet Respiratory Medicine**, p. S2213260020305609, jan. 2021.

SALKEVER, D. S. Accessibility and the demand for preventive care. **Social Science & Medicine (1967)**, v. 10, n. 9–10, p. 469–475, set. 1976.

SANCHEZ, R. M.; CICONELLI, R. M. Conceitos de acesso à saúde. **Revista Panamericana de Salud Pública**, v. 31, n. 3, p. 260–268, mar. 2012.

SCHNEIDER, A.; HOMMEL, G.; BLETTNER, M. Linear Regression Analysis. **Deutsches Aerzteblatt Online**, 5 nov. 2010.

SHAFIQUE, U.; QAISER, H. A Comparative Study of Data Mining Process Models (KDD, CRISP-DM and SEMMA). **International Journal of Innovation and Scientific Research**, v. 12, n. 1, p. 217–222, 2014.

SHEARER, C. The CRISP-DM Model: The New Blueprint for Data Mining. v. 5, p. 13–22, 2000.

SOCÍAS, M. E.; KOEHOORN, M.; SHOVELLER, J. Gender Inequalities in Access to Health Care among Adults Living in British Columbia, Canada. **Women's Health Issues**, v. 26, n. 1, p. 74–79, jan. 2016.

SOHRABI, C. et al. World Health Organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19). **International Journal of Surgery**, v. 76, p. 71–76, abr. 2020.

SPERANDEI, S. Understanding logistic regression analysis. **Biochemia Medica**, p. 12–18, 2014.

SZWARCWALD, C. L. et al. Inequalities in healthy life expectancy by Brazilian geographic regions: findings from the National Health Survey, 2013. **International Journal for Equity in Health**, v. 15, n. 1, p. 141, dez. 2016.

THAKUR, N. et al. The Structural and Social Determinants of the Racial/Ethnic Disparities in the U.S. COVID-19 Pandemic: What's Our Role? **American Journal of Respiratory and Critical Care Medicine**, p. rccm.202005-1523PP, 17 jul. 2020.

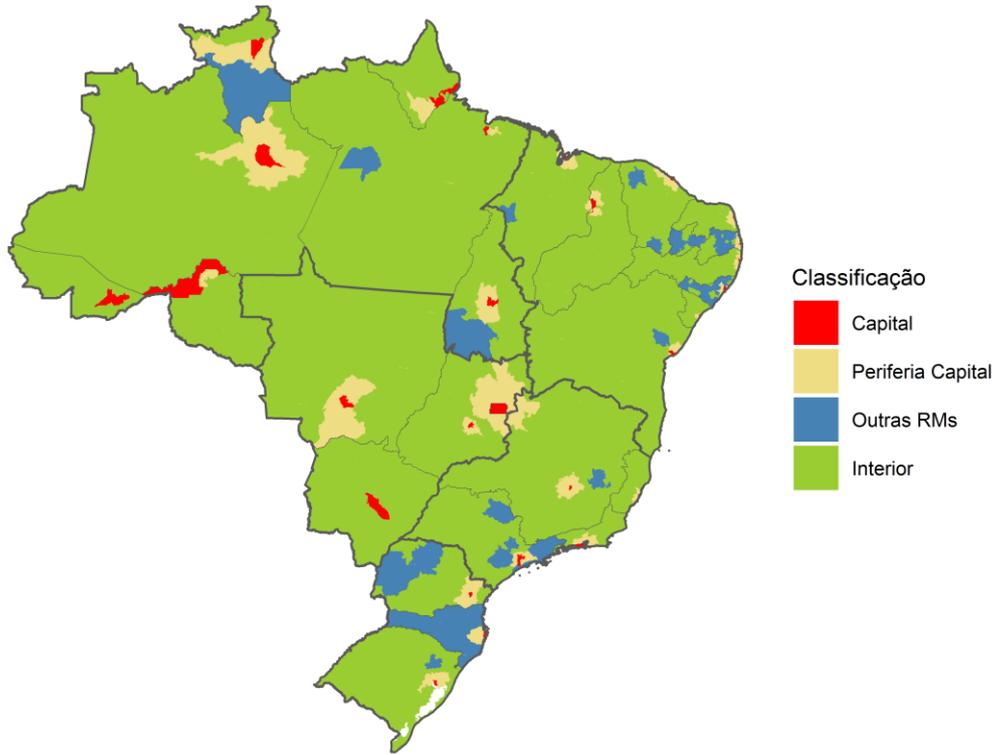
VAISHNAVI, V. K.; KUECHLER, W. **Design Science Research Methods and Patterns: Innovating Information and Communication Technology**. 0. ed. [s.l.] Auerbach Publications, 2007.

WATERS, H. R. Measuring equity in access to health care. **Social Science & Medicine**, v. 51, n. 4, p. 599–612, ago. 2000.

WENDT, C. Mapping European healthcare systems: a comparative analysis of financing, service provision and access to healthcare. **Journal of European Social Policy**, v. 19, n. 5, p. 432–445, dez. 2009.

WHITEHEAD, M. et al. As the health divide widens in Sweden and Britain, what's happening to access to care? **BMJ**, v. 315, n. 7114, p. 1006–1009, 18 out. 1997.

APÊNDICE I – Mapa do Brasil com cada município colorido a partir da classificação conforme Capital, Periferia da Capital, Outras RMs e Interior



APÊNDICE II – Mortalidade hospitalar por variável demográfica

Características	Mesmo Município	Município Diferente
Total	105897/310322 (34%)	41210/108924 (38%)
Faixa de idade		
20-39	3791/38015 (10%)	1985/13682 (15%)
40-49	6592/43494 (15%)	2980/15531 (19%)
50-59	13137/57212 (23%)	5752/20897 (28%)
60-69	24225/66156 (37%)	10008/23804 (42%)
70-79	28358/57421 (49%)	10910/20286 (54%)
80+	29794/48024 (62%)	9575/14724 (65%)
Sexo		
Masculino	60480/172876 (35%)	23932/62443 (38%)
Feminino	45407/137411 (33%)	17271/46461 (37%)
Cor de pele		
Branco	42991/128670 (33%)	16665/46614 (36%)
Preto/Pardo	39535/104528 (38%)	16063/36133 (44%)
Asiático	1233/3462 (36%)	388/1097 (35%)
Indígena	150/500 (30%)	153/299 (51%)
Nível de educação		
Analfabeto	3518/6176 (57%)	1697/2744 (62%)
Até o Ensino Médio	20375/47828 (43%)	8989/19172 (47%)
Ensino Médio	9845/35945 (27%)	3541/12201 (29%)
Ensino Superior	4302/19524 (22%)	1303/5712 (23%)
Região de residência		
Norte	7258/15859 (46%)	1816/3744 (49%)
Nordeste	18689/44253 (42%)	10671/21212 (50%)
Centro-Oeste	9172/29396 (31%)	2711/7063 (38%)
Sudeste	57146/174016 (33%)	18592/55272 (34%)
Sul	13632/46798 (29%)	7420/21633 (34%)
Número de comorbidades		
Nenhuma	5382/18626 (29%)	2229/6885 (32%)
1-2	35118/90022 (39%)	13340/32017 (42%)
>=3	6387/11464 (56%)	2415/4339 (56%)
Admissão na UTI		
Não	36854/178041 (21%)	10147/52628 (19%)
Sim	57732/102033 (57%)	27229/47107 (58%)
Suporte respiratório		
Não	10121/72036 (14%)	3112/21467 (14%)
Sim, não invasivo	38827/143843 (27%)	12867/48453 (27%)
Sim, invasivo	42145/53477 (79%)	19499/24673 (79%)

APÊNDICE III – Deslocamentos entre categorias de municípios por região do Brasil

Região	Residência	Internação				Casos com deslocamento	Casos sem deslocamento
		Capital	Periferia das capitais	Outras RMs	Interior		
Norte	Capital	256	82	9	72	419	10938
	Periferia das capitais	987	78	2	27	1094	840
	Outras RMs	74	6	56	5	141	610
	Interior	1323	100	78	898	2399	4818
Nordeste	Capital	123	769	24	117	1033	35403
	Periferia das capitais	7136	822	13	104	8075	2918
	Outras RMs	828	202	1257	79	2366	2521
	Interior	6644	435	791	5551	13421	9445
Centro-Oeste	Capital	141	738	14	62	955	23101
	Periferia das capitais	2365	390	4	233	2992	2127
	Outras RMs	0	0	0	0	0	0
	Interior	1805	297	34	1519	3655	6723
Sudeste	Capital	114	4357	115	223	4809	92493
	Periferia das capitais	17551	11077	103	515	29246	30700
	Outras RMs	1258	160	7854	385	9657	25681
	Interior	1465	840	719	13270	16294	40251
Sul	Capital	32	476	34	42	584	15754
	Periferia das capitais	5694	3024	122	182	9022	5447
	Outras RMs	202	67	6171	275	6715	15677
	Interior	745	532	551	4869	6697	11956

APÊNDICE IV – Mediana, primeiro quartil e terceiro quartil de características dos municípios

Características	Capital (n = 27)	Periferia das capitais (n = 398)	Outras RMs (n = 859)	Interior (n = 3846)
Hospitalizações por 100 mil habitantes	273 (216, 378)	141 (88, 217)	101 (53, 180)	75 (36, 140)
Óbitos hospitalares por 100 mil habitantes	105 (82, 117)	55 (33, 81)	37 (18, 61)	29 (13, 52)
Proporção de indivíduos que saíram do município	0,04 (0,01, 0,06)	0,90 (0,60, 1,00)	1,00 (0,72, 1,00)	1,00 (0,67, 1,00)
Distância média percorrida por indivíduos que saíram do município (Km)	570 (161, 1368)	51 (33, 80)	61 (39, 104)	107 (58, 204)
IDHM	0,77 (0,75, 0,80)	0,69 (0,65, 0,73)	0,70 (0,62, 0,74)	0,66 (0,60, 0,71)
Leitos por 10 mil habitantes	27 (22, 31)	6 (2, 11)	8 (0, 19)	8 (0, 17)
Leitos UTI por 10 mil habitantes	3,44 (2,56, 4,15)	0,00 (0,00, 0,13)	0,00 (0,00, 0,00)	0,00 (0,00, 0,00)
Casos totais por 100 mil habitantes	4723 (3653, 6952)	3082 (2022, 4688)	3275 (2194, 4972)	2552 (1610, 3859)
Óbitos totais por 100 mil habitantes	135 (118, 154)	80 (55, 108)	56 (36, 83)	49 (26, 80)

APÊNDICE V – Correlação de Spearman entre variáveis a nível de município

	Óbitos/100k	Óbitos/100k (fora)	Óbitos/100k (mesmo)	Hosp/100k	Proporção Fora	Dist. Média Fora	IDHM	Leitos/10k	Leitos UTI/10k	Casos/100k
Óbitos/100k	1	0,81	0,37	0,78	-0,26	-0,23	0,36	0,04	0,23	0,29
Óbitos/100k (fora)	0,81	1	-0,12	0,55	0,2	-0,34	0,14	-0,18	-0,17	0,17
Óbitos/100k (mesmo)	0,37	-0,12	1	0,38	-0,91	0,16	0,32	0,4	0,55	0,2
Hosp/100k	0,78	0,55	0,38	1	-0,32	-0,32	0,55	0,06	0,26	0,33
Proporção Fora	-0,26	0,2	-0,91	-0,32	1	-0,21	-0,31	-0,47	-0,52	-0,16
Dist. Média Fora	-0,23	-0,34	0,16	-0,32	-0,21	1	-0,3	0,25	0,13	0,03
IDHM	0,36	0,14	0,32	0,55	-0,31	-0,3	1	0,22	0,35	0,21
Leitos/10k	0,04	-0,18	0,4	0,06	-0,47	0,25	0,22	1	0,33	0,12
Leitos UTI/10k	0,23	-0,17	0,55	0,26	-0,52	0,13	0,35	0,33	1	0,17
Casos/100k	0,29	0,17	0,2	0,33	-0,16	0,03	0,21	0,12	0,17	1