

Brazilian States in the Context of COVID-19 Pandemic: An Index Proposition using Network Data Envelopment Analysis

Enzo B. Mariano, Bruno G. Torres, Mariana Rodrigues de Almeida, Diogo Ferraz, Daisy A. N. Rebelatto, João Carlos Soares de Mello

Abstract— This study aims to evaluate comparatively the situation of the federal units and the Brazilian states in relation to the pandemic of new coronaviruses (COVID19) through the technique of Network Data Envelopment Analysis (Network DEA - NDEA). For the development of research, data were collected on the Ministry of Health website, for all regions that register cases of virus cases notified until April 27, 2020. The purpose of the analysis is to assess regional discrepancies in the country. The model consists of the following structure: three *inputs* (number of doctors, number of respirators and number of clinical beds), an intermediate variable (number of reported cases) and one output (number of deaths). The results indicated that the federative unit with the worst performance overall was Amazonas, while the worst capital was Manaus. With two-dimensional representation, managers can visualize better which locations have the worst performance and assess which locations require more assistance. Depending on the results, managers can develop regional action plans, which can take steps to prevent the collapse of the health system.

Index Terms—COVID-19, Network Data Envelopment Analysis (NDEA), Healthcare, Two-dimensional Frontier Representation

I. INTRODUÇÃO

O presente estudo analisa o número de casos e óbitos notificados por coronavírus no Brasil relativamente a infraestrutura hospitalar das unidades federativas e capitais estaduais brasileiras. A COVID-19 é uma doença causada pelo coronavírus, que surgiu na China em 2019 e se tornou uma pandemia mundial em 2020 [1].

As discrepâncias geográficas encontradas no Brasil fazem com que a situação da doença seja distinta em cada região analisada. Assim, o objetivo deste artigo é a determinação de

Este trabalho foi apoiado pelas instituições científicas brasileiras, CAPES e CNPq.

E. B. Mariano, Departamento de Engenharia de Produção (DEP) da Universidade Estadual Paulista (UNESP), Bauru, São Paulo, Brasil, (e-mail: enzo.mariano@unesp.br).

B. G. Torres, estudante de doutorado na Universidade Federal Fluminense (UFF), Niterói, Rio de Janeiro, Brasil (e-mail: brunotorres@id.uff.br).

M. R. de Almeida, Departamento de Engenharia de Produção (DEP) da Universidade Federal do Rio Grande do Norte, Natal, Rio Grande do Norte, Brasil. (e-mail: almeidamariana@yahoo.com)

D. Ferraz, Universidade Federal Rural da Amazônia (UFRA), Parauapebas, Pará, Brasil, (e-mail: diogoferraz@alumni.usp.br).

D. A. N. Rebelatto, Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo, São Carlos, São Paulo, Brasil, (e-mail: daisy@usp.br)

J. C. C. B. Soares de Mello, Departamento de Engenharia de Produção (TEP) da Universidade Federal Fluminense (UFF), Niterói, Rio de Janeiro, Brasil, (e-mail: jcsmllo@gmail.com).

um índice que permita avaliar a situação das unidades federativas e das capitais estaduais do Brasil em relação à pandemia do novo coronavírus (COVID19).

Desta forma, o índice poderá identificar quais são as unidades federativas e as capitais mais preparadas para combater a pandemia, bem como as regiões com a situação mais preocupante. Vale destacar que uma análise das discrepâncias geográficas no continente africano já foi realizada em [2].

No Brasil, o sistema de saúde acompanha a heterogeneidade social e econômica. De forma geral, as regiões Sul e Sudeste possuem sistemas hospitalares mais desenvolvidos do que o Norte e o Nordeste do país, o que dificulta o enfrentamento da pandemia do coronavírus. Por exemplo, o número de respiradores é distribuído de forma desigual, pois enquanto a região Sudeste possui 39,91 respiradores a cada cem mil habitantes, essa proporção nas regiões Nordeste e Norte são de respectivamente: 22,90 e 19,06, o que pode ocasionar graves problemas. O mesmo ocorre para as Unidades de Terapia Intensiva (UTIs), pois o Sudeste (20,22), Sul (15,83) e o Centro-Oeste (22,39) possuem maior número de UTIs a cada cem mil habitantes do que o Norte (7,97) e o Nordeste (11,01). Essa desigualdade também pode ser observada nas capitais brasileiras. Por exemplo, enquanto São Paulo possui 3.337 UTIs e 6.772 respiradores, Manaus possui apenas 786 UTIs e 273 respiradores [3]. Os dados demonstram que a pandemia poderá afetar de forma desigual as regiões brasileiras, pois a infraestrutura hospitalar no Norte e no Nordeste pode entrar em colapso mais rapidamente do que nas demais regiões do país, mesmo com um menor número de casos.

Neste artigo propõe-se avaliar quantitativamente a situação dos estados brasileiros e de suas capitais perante a pandemia de COVID-19. Para tal, utilizou-se a Análise Envoltória de Dados em redes (NDEA), com a modelagem proposta por [4], que permite avaliar separadamente um conjunto de estágios produtivos, bem como determinar um índice global que indica o quão vulnerável se encontra um determinado estado/capital perante a pandemia.

Esse modelo foi aplicado na avaliação dos seguintes dois estágios, que representam respectivamente: (1) a situação da infraestrutura do estado/capital relativamente ao número de casos e a (2) a taxa de mortalidade por COVID-19 no estado/capital. Esses estágios também foram utilizados na representação bidimensional da fronteira de eficiência proposta neste estudo.

A amostra analisada inclui os 26 Unidades Federativas

brasileiras mais o Distrito Federal, bem como as microrregiões das quais fazem parte suas capitais. A obtenção dos dados foi realizada por meio do portal [5]. Optou-se por escolher microrregiões porque cidades menores dependem dos serviços públicos da capital [6]. A definição de microrregião adotada por este estudo é aquela apresentada pelo Instituto Brasileiro de Geografia e Estatística – IBGE. Segundo o IBGE, as microrregiões são pequenos agrupamentos de municípios delimitados a partir de sua organização espacial e de sua estrutura produtiva [7].

Neste trabalho, visa-se estabelecer uma relação lógica entre os recursos do sistema de saúde e o número de casos e mortes causados pela pandemia. Durante a revisão bibliográfica, constatou-se que poucos trabalhos avaliam o sistema de saúde por meio de modelos NDEA, em especial no que concerne a estudos sobre pandemias.

O artigo está organizado nas seguintes seções: inicialmente, apresentam-se os conceitos sobre NDEA; a seguir, apresenta-se o método aplicado para o desenvolvimento do presente trabalho, detalhando-se a modelagem de NDEA proposta em [4]; A quarta seção elucida os resultados encontrados, a quinta seção discute os resultados apresentados, enquanto a seção final apresenta as principais conclusões e as proposições de avanços em futuros estudos.

II. NETWORK DEA

A Análise Envoltória de Dados (DEA) é uma técnica desenvolvida por [8], que mede e compara a eficiência relativa de unidades produtivas, chamadas Unidades Tomadoras de Decisão (*Decision Making Units* – DMU), com a utilização de múltiplos *inputs* e múltiplos *outputs*. Diversos modelos DEA foram construídos na literatura a fim de suprir ou adequar necessidades específicas para cada problema [9].

Ao longo dos anos, a complexidade dos sistemas vem aumentando, o que exige novas abordagens, pois os modelos clássicos visualizavam os sistemas como uma “caixa preta”, ignorando os processos individuais dentro de um sistema [10]. Assim, [11] propuseram a abertura da “caixa preta” e introduziram o modelo Network DEA ou “NDEA”. O objetivo do NDEA é analisar o desempenho de uma DMU de forma que sejam observados os processos que compõem os diferentes estágios de um processo produtivo. Ademais, o NDEA verifica quais são as causas dos eventuais ganhos de eficiência, permitindo maiores informações para os tomadores de decisão. Diversos modelos NDEA foram desenvolvidos na literatura para mensurar a eficiência dos sistemas de produção em rede [12].

Aplicações com a utilização de modelos NDEA já foram realizadas em distintos campos de estudo, como: energia [13], educação [14], finanças [15] e saúde [16]–[20].

Em 2016, [4] introduziram um novo modelo NDEA multiobjetivo para sanar algumas deficiências dos modelos anteriores como, por exemplo, a não unicidade de soluções e a prevalência de um estágio sobre outro. O modelo se baseia no DEA clássico proposto por [8]. O Modelo 1 corresponde à eficiência do primeiro estágio e está orientado aos *outputs*. O Modelo 2 determina a eficiência do segundo estágio e está

orientado aos *inputs*. Nos Modelos 1 e 2, E_0^1 e E_0^2 correspondem a eficiência do estágio analisado, u_r, v_i, w_d são os multiplicadores das variáveis e x, y, z , os valores dos *inputs*, dos *outputs* e das variáveis intermediárias, respectivamente. Os pesos das variáveis intermediárias são os mesmos para os dois modelos.

$$\begin{aligned} E_0^1 &= \min \frac{\sum_{i=1}^m v_i x_{i0}}{\sum_{d=1}^D w_d z_{d0}} \\ \text{s. t. } \frac{\sum_{i=1}^m v_i x_{ij}}{\sum_{d=1}^D w_d z_{dj}} &\geq 1, j = 1, 2, \dots, n \\ v_i, w_d &\geq 0; i = 1, 2, \dots, m; d = 1, 2, \dots, D \end{aligned} \quad (1)$$

$$\begin{aligned} E_0^2 &= \max \frac{\sum_{r=1}^s u_r y_{r0}}{\sum_{d=1}^D w_d z_{d0}} \\ \text{s. t. } \frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{d=1}^D w_d z_{dj}} &\leq 1, j = 1, 2, \dots, n \\ u_r, w_d &\geq 0; r = 1, 2, \dots, s; d = 1, 2, \dots, D \end{aligned} \quad (2)$$

O modelo proposto por [4] agrega os Modelos 1 e 2, tanto para as restrições quanto para as funções objetivos, o que cria um modelo multiobjetivo. Dessa forma, o modelo pretende encontrar simultaneamente uma solução que busca a melhor eficiência para o primeiro e para o segundo estágio, a fim de respeitar as restrições que garantam que a eficiência de cada estágio interno é igual ou menor que 1. Como o modelo gerado é não-linear, uma transformação de linearização pode ser realizada [8], pois os denominadores das duas funções objetivo são idênticos. Assim, o modelo resultante se encontra expresso em 3.

$$\begin{aligned} E_0^1 &= \min \sum_{i=1}^m v_i x_{i0} \\ E_0^2 &= \max \sum_{r=1}^s u_r y_{r0} \\ \text{s. t. } \sum_{d=1}^D w_d z_{d0} &= 1 \\ \sum_{d=1}^D w_d z_{dj} - \sum_{i=1}^m v_i x_{ij} &\leq 0, j = 1, 2, \dots, n \\ \sum_{r=1}^s u_r y_{rj} - \sum_{d=1}^D w_d z_{dj} &\leq 0, j = 1, 2, \dots, n \\ u_r, v_i, w_d &\geq 0, i = 1, 2, \dots, m, r = 1, 2, \dots, s, d = 1, 2, \dots, D \end{aligned} \quad (3)$$

O procedimento selecionado por [4] para a resolução do problema multiobjetivo foi a minimização do máximo desvio de um ponto da Fronteira de Pareto ($\sum_{i=1}^m v_i x_{i0}, \sum_{r=1}^s u_r y_{r0}$) até o ponto ideal (E_0^1, E_0^2), utilizando a distância não ponderada de Tchebycheff. A primeira coordenada do ponto ideal a ser determinado é o melhor resultado para a eficiência do primeiro estágio na Fronteira de Pareto. A segunda coordenada é o melhor valor de eficiência do segundo estágio para a mesma fronteira.

O modelo 4 soluciona o problema anteriormente descrito onde δ é o maior dos desvios.

$$\begin{aligned} \min \delta \\ \text{s. t. } \sum_{i=1}^m v_i x_{i0} - \delta &\leq E_{j0}^1 \\ \sum_{r=1}^s u_r y_{r0} + \delta &\geq E_{j0}^2 \\ \sum_{d=1}^D w_d z_{d0} &= 1 \\ \sum_{d=1}^D w_d z_{dj} - \sum_{i=1}^m v_i x_{ij} &\leq 0, j = 1, 2, \dots, n \\ \sum_{r=1}^s u_r y_{rj} - \sum_{d=1}^D w_d z_{dj} &\leq 0, j = 1, 2, \dots, n \\ u_r, v_i, w_d, \delta &\geq 0, i = 1, 2, \dots, m, r = 1, 2, \dots, s, d = 1, 2, \dots, D \end{aligned} \quad (4)$$

O modelo 4 encontra a solução em que os desvios do ponto ideal são iguais e minimizados. Por exemplo, na Figura 1, a solução do problema é o ponto F, que é o ponto mais próximo entre a Fronteira de Pareto (ABCD) e o ponto ideal, através da distância de Tchebycheff.

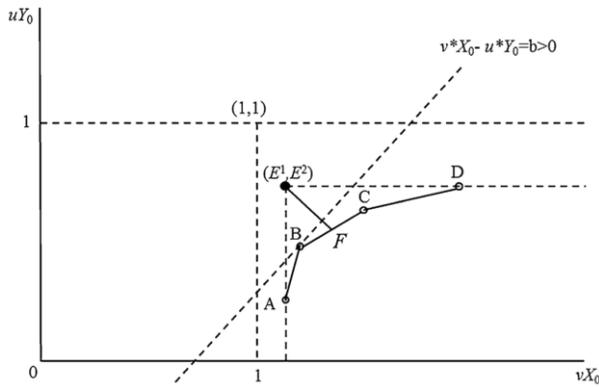


Fig. 1. Fronteira de Pareto do MOLP e sua solução ótima [4]

Uma vez que a solução ótima (v^*, w^*, u^*) foi encontrada no modelo 4, os valores de eficiência de cada estágio para a DMU em avaliação são encontrados pelas Equações 5 para o primeiro estágio, e 6 para o segundo estágio. Note que a variável intermediária virtual tem sempre o valor igual a 1. Sendo assim, a eficiência do primeiro estágio é igual ao inverso do *input* virtual exógeno, enquanto a eficiência do segundo estágio é igual ao valor do *output* virtual exógeno.

$$E_0^1 = \frac{\sum_{d=1}^D w_d z_{d0}}{\sum_{i=1}^m v_i x_{i0}} = \frac{1}{\sum_{i=1}^m v_i x_{i0}} \quad (5)$$

$$E_0^2 = \frac{\sum_{r=1}^S u_r y_{r0}}{\sum_{d=1}^D w_d z_{d0}} = \sum_{r=1}^S u_r y_{r0} \quad (6)$$

As eficiências dos dois estágios internos precisam ser agregadas para se obter a eficiência global, que pode ser definida como a média aritmética das eficiências dos estágios internos, como em 7, ou pode ser agregada multiplicativamente, como em 8.

$$E_0 = \frac{1}{2} (E_0^1 + E_0^2) \quad (7)$$

$$E_0 = E_0^1 * E_0^2 = \frac{1}{\sum_{i=1}^m v_i x_{i0}} * \sum_{r=1}^S u_r y_{r0} = \frac{\sum_{r=1}^S u_r y_{r0}}{\sum_{i=1}^m v_i x_{i0}} \quad (8)$$

A fim de facilitar a interpretação dos resultados obtidos, será proposto um modelo de representação bidimensional da fronteira de eficiência. Esse modelo será baseado no estudo desenvolvido por [21] que propôs a representação bidimensional para o DEA clássico.

III. MODELAGEM

No modelo NDEA utilizado neste trabalho foram utilizados como *input* a quantidade de: (X_1) médicos, (X_2) respiradores e (X_3) leitos clínicos; como *output*, utilizou-se o (Y_1) Número de óbitos; já como variável intermediária (Z_1) adotou-se a

quantidade de casos notificados de coronavírus, que faz a ligação entre a estrutura hospitalar e o número de óbitos causados pela doença, conforme ilustrado pela Figura 2.

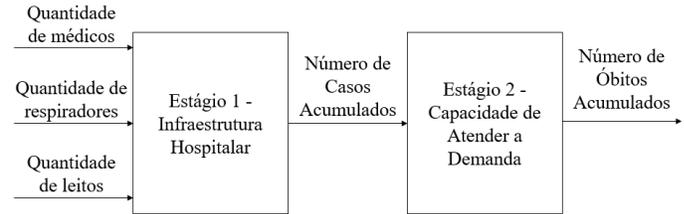


Fig. 2. Modelo NDEA utilizado

Vale ressaltar que foram utilizados dados acumulados referentes ao dia 27 de abril de 2020, que se encontram exibidos na Tabela 1 para as Unidades Federativas e na Tabela 2 para as Microrregiões onde estão localizadas as Capitais Estaduais. Destaca-se também que tanto o número de óbitos quanto o número de casos confirmados por coronavírus estão sujeitos a problemas de subnotificação [22].

TABELA I
DADOS RELACIONADOS AS UNIDADES FEDERATIVAS

DMUS	X ₁	X ₂	X ₃	Z ₁	Y ₁
AC	397	145	1149	301	14
AL	1075	499	4706	632	32
AM	1223	895	5284	3833	304
AP	240	94	1066	842	26
BA	4611	2921	20587	2340	82
CE	3220	2123	17122	6236	375
DF	2091	2127	6705	1051	27
ES	2087	1424	7160	1846	62
GO	3272	1627	13684	614	26
MA	1339	928	8916	2528	145
MG	12101	5609	31011	1568	62
MS	1831	837	4141	238	9
MT	1377	1227	4657	249	9
PA	2251	1321	11358	2199	122
PB	1153	826	6461	543	50
PE	3451	2834	18665	3301	380
PI	817	432	5961	408	21
PR	8122	3533	21854	1186	75
RJ	9670	7485	32308	7944	677
RN	1161	787	5868	773	39
RO	648	414	2932	393	9
RR	395	152	1073	425	4
RS	7806	3072	22912	1256	45
SC	5216	1937	12035	1456	44
SE	951	493	3012	211	11
SP	29965	18204	85592	21696	1825
TO	600	294	2142	79	2

TABELA II
DADOS RELACIONADOS AS MICRORREGIÕES ONDE ESTÃO LOCALIZADAS AS
CAPITAIS ESTADUAIS

DMUS	X_1	X_2	X_3	Z_1	Y_1
Rio Branco	352	129	974	296	14
Maceió	802	403	2990	576	25
Manaus	1002	845	3547	3128	274
Macapá	217	92	890	784	23
Salvador	2324	1696	9335	1544	53
Fortaleza	1769	1493	9294	5585	329
Brasília	2091	2127	6705	1051	27
Vitória	1169	915	3646	1586	56
Goiânia	1835	1123	8470	411	14
São Luis	718	604	3983	2214	131
Belo Horizonte	4813	2174	10822	718	13
Cuiabá	1017	587	2258	127	2
Campo Grande	625	804	2400	138	1
Belém	1385	843	4634	1603	78
João Pessoa	552	511	3100	428	39
Recife	1996	2159	10804	2864	293
Teresina	399	295	3310	284	9
Paraná	3149	1605	8482	537	19
Rio de Janeiro	6427	5717	20759	7115	601
Natal	690	570	3235	472	10
Porto velho	359	309	1802	288	6
Boa Vista	384	149	974	402	4
Porto Alegre	3267	1585	9778	612	20
Florianópolis	1047	578	2758	361	10
Aracaju	755	405	2248	154	7
São Paulo	9803	8504	32986	15429	1263
Palmas	218	168	956	37	1

O modelo desenvolvido contempla dois estágios: Estágio 1 (E_1) e Estágio 2 (E_2). O objetivo do primeiro estágio é avaliar o quanto cada região está preparada para atender os pacientes infectados pela COVID-19 em relação as demais regiões. Nessa modelagem, as DMUs com o maior valor obtido no modelo (valor igual a 1) são as regiões que possuem o pior desempenho. Isso ocorre pois se deseja encontrar aquelas DMUs que possuem menor número de casos em relação à infraestrutura hospitalar. O Estágio 1, portanto, fornece um indicador invertido, de modo que quanto menor o seu valor, melhor é a performance da DMU; ressalta-se que essa abordagem invertida já foi previamente utilizada em [23].

O Estágio 2, por outro lado, representaria, se não houvesse subnotificação, a eficácia com que cada região tem conseguido tratar os casos COVID-19 com o objetivo de minimizar o número de óbitos, sendo uma espécie de taxa de mortalidade. Sendo assim, as regiões com os maiores valores calculados no modelo são aquelas DMUs com o pior desempenho, ou seja,

aquelas em que mais casos notificados resultam em morte.

A mesma lógica do primeiro estágio ocorre para o estágio global. A diferença é que, nesse estágio, o número de mortes é relativizado pela infraestrutura hospitalar. O resultado nesse caso também é invertido, pois busca-se analisar quais são as regiões que obtêm o menor número de óbitos em relação à infraestrutura hospitalar disponível. Nesse estudo, o índice global foi obtido por meio da multiplicação dos valores dos estágios internos de cada DMU.

A fim de obter a representação bidimensional das DMUs, deve-se analisar a restrição de linearização do modelo. Como no modelo proposto a restrição de linearização tem relação com a variável intermediária, foi possível utilizar os valores originais do *input* virtual e do *output* virtual, diferentemente dos modelo proposto por [21]. Em um gráfico que relaciona o *input* virtual com o *output* virtual, nenhum dos eixos teria valores iguais a 1 para todas as DMUs.

Para a elaboração da representação bidimensional, o *input* virtual será representado no eixo x e o *output* virtual será representado no eixo y. Quando esses valores são iguais, o resultado da DMU é 1; pode-se definir como fronteira a reta que cruza a DMU (real ou hipotética) cujo indicador global é igual a 1. Quanto mais próxima da fronteira, em pior situação está a DMU.

IV. RESULTADOS

A Tabela 3 apresenta os resultados obtidos com o NDEA para as unidades federativas brasileiras, bem como para as microrregiões onde estão localizadas as capitais estaduais e o Distrito Federal. Dessa forma, são apresentados: o resultado do primeiro estágio (E_1), o resultado do segundo estágio (E_2), e o resultado global (E_0). Vale destacar que, para o modelo adotado, quanto maior o indicador determinado pelo modelo pior a performance da região analisada.

TABELA III
RESULTADOS DO NDEA PARA AS REGIÕES BRASILEIRAS

UF	Unidades Federativas (UFs)			Microrregiões com Capitais Estaduais			
	E_1	E_2	E_0	Capital	E_1	E_2	E_0
AC	0,332	0,404	0,134	Rio Branco	0,345	0,462	0,159
AL	0,170	0,440	0,075	Maceió	0,219	0,424	0,093
AM	0,918	0,689	0,633	Manaus	1	0,856	0,856
AP	1	0,268	0,268	Macapá	1	0,287	0,287
BA	0,145	0,304	0,044	Salvador	0,188	0,336	0,063
CE	0,552	0,522	0,288	Fortaleza	0,874	0,576	0,503
DF	0,198	0,223	0,044	Brasília	0,178	0,251	0,045
ES	0,326	0,292	0,095	Vitória	0,493	0,345	0,170
GO	0,057	0,368	0,021	Goiânia	0,062	0,333	0,021
MA	0,538	0,498	0,268	São Luis	0,853	0,578	0,494
MG	0,064	0,343	0,022	Belo Horizonte	0,075	0,177	0,013
MS	0,073	0,328	0,024	Cuiabá	0,064	0,154	0,010
MT	0,068	0,314	0,021	Campo Grande	0,065	0,071	0,005
PA	0,278	0,482	0,134	Belém	0,392	0,476	0,187

PB	0,134	0,800	0,107	João Pessoa	0,215	0,891	0,191
PE	0,273	1	0,273	Recife	0,397	1	0,397
PI	0,142	0,447	0,064	Teresina	0,197	0,310	0,061
PR	0,069	0,549	0,038	Paraná	0,072	0,346	0,025
RJ	0,311	0,740	0,230	Rio de janeiro	0,389	0,826	0,321
RN	0,190	0,438	0,083	Natal	0,189	0,207	0,039
RO	0,173	0,199	0,034	Porto velho	0,222	0,204	0,045
RR	0,501	0,082	0,041	Boa Vista	0,468	0,097	0,046
RS	0,069	0,311	0,022	Porto Alegre	0,071	0,319	0,023
SC	0,153	0,263	0,040	Florianópolis	0,148	0,271	0,040
SE	0,089	0,453	0,040	Aracaju	0,078	0,444	0,035
SP	0,321	0,731	0,234	São Paulo	0,530	0,800	0,424
TO	0,047	0,220	0,010	Palmas	0,047	0,264	0,012

Para a melhor compreensão dos indicadores foi desenvolvida a representação bidimensional da fronteira para os resultados calculados. A Figura 3 ilustra o desempenho das unidades federativas do Brasil. A Figura 4 mostra o desempenho das microrregiões com capitais estaduais. Em ambas as figuras, apresenta-se a fronteira, representada pela linha pontilhada vertical que identifica as regiões com máximo indicador no primeiro estágio e pela linha pontilhada horizontal que identifica as regiões com pior desempenho no segundo estágio; apresenta-se também uma hipérbole que divide as DMUs entre as que possuem uma situação mais preocupante no primeiro estágio do que no segundo (abaixo da hipérbole) e as que possuem uma situação mais preocupante no segundo estágio do que no primeiro (acima da hipérbole).

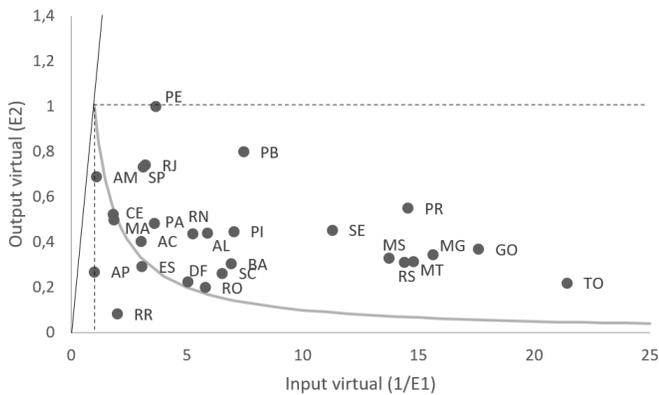


Fig. 3. Representação bidimensional para os resultados das Unidades Federativas

Ressalta-se que nessas figuras o eixo x (*input virtual*) representa o inverso do valor da eficiência do primeiro estágio; dessa forma, quanto mais distante do eixo y um determinado estado ou capital estiver, menor a possibilidade de colapso do sistema de saúde. O eixo y (*output virtual*), por outro lado, corresponde ao próprio valor da eficiência do segundo estágio, que é a taxa de mortalidade da COVID-19; sendo assim, quanto mais distante do eixo x uma região estiver, maior será o nível de mortalidade decorrente do coronavírus.

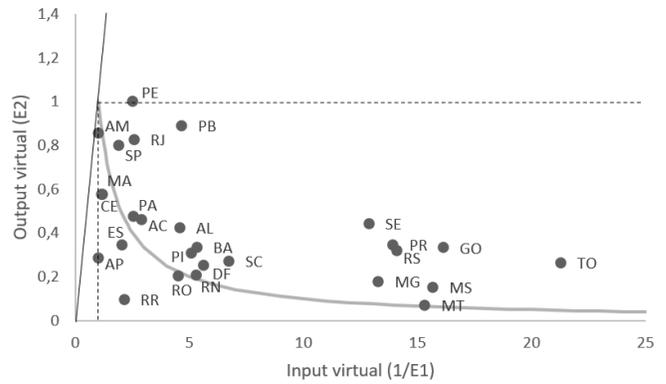


Fig. 4. Representação bidimensional para os resultados das Microrregiões com Capitais Estaduais

Nota-se nas Figuras 3 e 4 que nenhuma DMU está localizada na fronteira. As DMUs que se encontram mais próximas, como o estado do Amazonas e a capital Manaus, todavia, apresentam uma situação preocupante, pois isso indica que lá existe alta taxa de mortalidade devido ao COVID-19, combinada a uma infraestrutura hospitalar limitada em relação ao número de casos da doença.

V. DISCUSSÕES

O primeiro estágio (E_1) representa o quanto a infraestrutura hospitalar (respiradores, médicos e leitos) de uma determinada região é suficiente para atender os pacientes infectados. Este índice é uma importante ferramenta para a tomada de decisão porque demonstra a vulnerabilidade do sistema hospitalar (infraestrutura e capital humano) frente ao número de casos confirmados por coronavírus.

O E_1 pode indicar, de maneira mais adequada e completa que a taxa de ocupação de leitos, que usualmente, é veiculada pelas autoridades públicas, o quanto a situação de uma determinada região pode ser potencialmente perigosa para o setor da saúde. Sua vantagem reside no fato de ele pode indicar uma situação potencialmente perigosa, mesmo que os casos de COVID-19 ainda não tenham evoluído e resultado em um grande número de internações.

O estado do Amapá, por exemplo, possui uma quantidade de pessoas contaminadas relativamente alta para o pequeno sistema hospitalar local. O mesmo ocorre com a microrregião de Macapá, capital do estado. Por outro lado, São Paulo e Rio de Janeiro concentram o maior número de casos confirmados do país, mas sua infraestrutura hospitalar é melhor do que a de regiões menos desenvolvidas, o que garantiu, até o momento, o atendimento dos casos de COVID-19; esses estados, todavia, se encontram próximos da fronteira. O Tocantins apesar de possuir uma infraestrutura hospitalar relativamente limitada, possui baixa quantidade de casos confirmados de COVID-19; por este motivo, o estado está em uma situação de menor vulnerabilidade quando comparado às demais unidades federativas do Brasil.

Ainda em termos do E_1 , quando se compara a situação do estado com a situação das capitais, a maioria apresenta situações semelhantes, como pode ser verificado pela comparação das Figuras 3 e 4. Todavia, existem exceções

como Belém, que está em situação de grande vulnerabilidade, ao contrário do estado do Pará.

O resultado do Estágio 2 (E_2) apresenta a relação entre o número de óbitos e o número de casos confirmados por COVID-19, sendo, portanto, a taxa de mortalidade apurada nas regiões analisadas. A taxa de mortalidade poderia ser interpretada como uma medida de eficácia do sistema hospitalar em salvar as vidas dos pacientes infectados, que ficaria bastante comprometida caso o sistema hospitalar entrasse em colapso. Entretanto, deve-se considerar também que a taxa de mortalidade pode ser afetada por diversos fatores ambientais, a saber: a idade média e o nível de comorbidades da população local. O E_2 também pode ser bastante impactado pela subnotificação de casos, sendo que um alto índice de mortalidade em uma determinada região pode indicar que há subnotificação dos casos registrados no local.

Pernambuco, por exemplo, ocupa o topo do ranking em E_2 , o que pode indicar que haja mais pessoas infectadas do que os casos notificados oficialmente. Paraíba, Rio de Janeiro, São Paulo e Amazonas também podem apresentar alta subnotificação, sendo que a situação é ainda pior nas capitais João Pessoa, Rio de Janeiro, São Paulo e Manaus. Minas Gerais, Mato Grosso e Mato Grosso do Sul, por sua vez, apresentam situação melhor nas capitais do que no estado em geral. Apesar de a subnotificação ser um problema a ser considerado, o alto índice de mortalidade também pode indicar que os doentes não estão sendo tratados de forma adequada, ou que não há tratamento disponível para todos os infectados pela doença (colapso).

Unindo os dois estágios em uma medida global (E_0), obtém-se o indicador mais importante deste estudo, que sinaliza as regiões que estão em situação mais sensível, exigindo maior atenção das autoridades federais, estaduais e municipais. Esta vulnerabilidade pode se dar devido ao elevado número de casos confirmados diante do tamanho do sistema de saúde (E_1), ou pelo excesso de mortalidade (E_2), que pode advir de uma ineficácia do sistema de saúde, de fatores ambientais diversos e da subnotificação dos casos.

No índice global, o Amazonas é o estado que apresenta a pior situação estando mais próximo da fronteira. Outros estados que também apresentam situação global preocupante são: Ceará, Pernambuco, Maranhão, Amapá, São Paulo e Rio de Janeiro. Entre as capitais estaduais, que de modo geral se encontram em situação significativamente pior do que as unidades federativas, Manaus (capital do Amazonas) apresentou a pior situação, seguida por Fortaleza, São Luís, São Paulo, Recife e Rio de Janeiro.

Vale ressaltar que os *rankings* obtidos neste trabalho podem ser utilizados pelas autoridades públicas para a melhor utilização dos recursos do sistema de saúde. Além disso, é interessante que esses dados sejam atualizados periodicamente para que se identifiquem mudanças no *ranking* das regiões brasileiras, o que continuaria balizando os planos de ação desenvolvidos pelo Poder Público, bem como para auxiliar na tomada de decisão dos gestores.

VI. CONCLUSÃO

O presente artigo apresentou a análise das unidades federativas e das capitais do Brasil com relação à capacidade

da infraestrutura hospitalar no combate à pandemia da COVID-19. Foi aplicado um modelo NDEA proposto por [4] nos dados obtidos para as regiões brasileiras até o dia 27 de abril de 2020. A modelagem foi dividida em dois estágios. O primeiro estágio mediu a capacidade das regiões em atender os infectados por meio da infraestrutura hospitalar local. O segundo estágio analisou a taxa de mortalidade de cada região, enquanto o estágio global comparou a quantidade de óbitos em relação a infraestrutura hospitalar regional. Diferentemente dos modelos NDEA clássicos, o modelo proposto apresenta um resultado invertido, ou seja, quanto maior o valor calculado em cada estágio, pior o desempenho da DMU analisada.

Uma representação bidimensional da fronteira também foi proposta. Essa representação auxilia a melhor interpretação dos resultados obtidos, em especial, dos gestores e tomadores de decisão que não estão familiarizados com o DEA.

De acordo com os resultados, os estados com o pior desempenho (acima de 0,8) no primeiro estágio foram Amazonas e Amapá, enquanto as piores capitais foram Manaus, Macapá e Fortaleza. Esse indicador aponta que há elevado número de casos notificados em cada uma das regiões analisadas, o que torna sua situação bastante preocupante em relação às demais localidades. Neste sentido, as autoridades do país deveriam priorizar políticas públicas nestes locais.

No segundo estágio, os estados com situação mais preocupante (acima de 0,8) são Pernambuco e Paraíba, enquanto as piores capitais são Recife, João Pessoa, Manaus, São Paulo e Rio de Janeiro. Essas regiões possuem taxa de mortalidade mais alta em relação às demais regiões analisadas. Estudos futuros devem verificar os determinantes das altas taxas de mortalidade em algumas regiões, bem como apresentar medidas para diminuição da vulnerabilidade do sistema hospitalar.

O estágio global aponta o Amazonas e a capital Manaus como as regiões com o pior desempenho no Brasil. O indicador global mostrou ainda que o sistema hospitalar da capital foi mais afetado pela pandemia do que o estado. Recomenda-se a elaboração de planos de ação com o intuito de arrefecer a vulnerabilidade do sistema hospitalar na região, tendo em vista a infraestrutura precária e a alta taxa de mortalidade local.

Estudos futuros podem também replicar o modelo proposto considerando dados atualizados, que levem em consideração a compra de respiradores, contratação de médicos e construção de hospitais de campanha em cada região. Dessa forma, será possível comparar momentos distintos no tempo, bem como analisar se as ações governamentais têm surtido efeito para o combate à pandemia. Seria possível também aplicar o modelo DEA dinâmico, a fim de analisar variações dos fatores analisados no tempo [24-25]. Outros tipos de abordagem podem ser desenvolvidas para compreender a pandemia, por exemplo, o modelo dinâmico com redes, que visa compreender tanto as falhas internas do sistema e a evolução dos casos notificados [26], a avaliação dos efeitos dos diferentes tamanhos relativos dos estados e capitais [27] e a associação destes resultados com a eficiência social regional [6].

AGRADECIMENTOS

Os autores gostariam de agradecer às instituições brasileiras de ciências, CAPES e CNPq, pelo apoio financeiro dado à pesquisa apresentada neste artigo, realizada durante o programa de doutorado e pós doutorado da UFF, em Niterói, do segundo e terceiro autores.

REFERÊNCIAS

- [1] A. Lee e J. Morling, “COVID19 - The need for Public Health in a time of emergency”, *Public Health*, abr. 2020, doi: 10.1016/j.puhe.2020.03.027.
- [2] I. A. Adekunle, A. T. Onanuga, O. O. Akinola, e O. W. Ogunbanjo, “Modelling spatial variations of coronavirus disease (COVID-19) in Africa”, *Sci. Total Environ.*, vol. 729, pp. 138-998, ago. 2020, doi: 10.1016/j.scitotenv.2020.138998.
- [3] “DATASUS”. <http://www2.datasus.gov.br/DATASUS/index.php?area=02> (acessado maio 11, 2020).
- [4] D. Despotis, G. Koronakos, e D. Sotiros, “Composition versus decomposition in two-stage network DEA: a reverse approach”, *J. Product. Anal.*, vol. 45, no 1, pp. 71–87, 2016, doi: <https://doi.org/10.1007/s11123-014-0415-x>.
- [5] “Dados COVID-19 - Brasil”. <https://covid.saude.gov.br/> (acessado maio 12, 2020).
- [6] D. Ferraz, E. B. Mariano, D. Rebelatto, e D. Hartmann, “Linking Human Development and the Financial Responsibility of Regions: Combined Index Proposals Using Methods from Data Envelopment Analysis”, *Soc. Indic. Res.*, abr. 2020, doi: 10.1007/s11205-020-02338-3.
- [7] Instituto Brasileiro de Geografia e Estatística (IBGE), “Divisão regional do Brasil em mesorregiões e microrregiões geográficas”, 1990. http://web.archive.org/web/20190120140831/http://biblioteca.ibge.gov.br/visualizacao/livros/liv2269_1.pdf (acessado jul. 05, 2020).
- [8] A. Charnes, W. W. Cooper, e E. Rhodes, “Measuring the efficiency of decision making units”, *Eur. J. Oper. Res.*, vol. 2, no 6, pp. 429–444, 1978.
- [9] W. D. Cook e L. Seiford, “Data envelopment analysis (DEA) - Thirty years on”, *Eur. J. Oper. Res.*, vol. 192, no 1, pp. 1–17, 2009.
- [10] C. Kao, “Efficiency decomposition in network data envelopment analysis: A relational model”, *Eur. J. Oper. Res.*, vol. 192, no 3, pp. 949–962, 2009, doi: 10.1016/j.ejor.2007.10.008.
- [11] R. Färe e S. Grosskopf, “Network DEA”, *Socioecon. Plann. Sci.*, vol. 34, no 1, pp. 35–49, mar. 2000, doi: 10.1016/S0038-0121(99)00012-9.
- [12] C. Kao, “Network data envelopment analysis: A review”, *Eur. J. Oper. Res.*, vol. 239, no 1, pp. 1–16, nov. 2014, doi: 10.1016/j.ejor.2014.02.039.
- [13] P. Moreno, G. Naciff Andrade, L. Angulo Meza, e J. C. Soares de Mello, “Evaluation of Brazilian electricity distributors using a Network DEA model with shared inputs”, *IEEE Lat. Am. Trans.*, vol. 13, no 7, pp. 2209–2216, jul. 2015, doi: 10.1109/TLA.2015.7273779.
- [14] L. A. Meza *et al.*, “Evaluación de los programas de post-grado usando un modelo de análisis envolvente de datos en red”, *DYNA*, vol. 85, n° 204, pp. 83–90, mar. 2018, doi: 10.15446/dyna.v85n204.60207.
- [15] C. Kao e S.-N. Hwang, “Efficiency decomposition in two-stage data envelopment analysis: An application to non-life insurance companies in Taiwan”, *Eur. J. Oper. Res.*, vol. 185, no 1, pp. 418–429, fev. 2008, doi: 10.1016/j.ejor.2006.11.041.
- [16] H. Kawaguchi, K. Tone, e M. Tsutsui, “Estimation of the efficiency of Japanese hospitals using a dynamic and network data envelopment analysis model”, *Health Care Manag. Sci.*, vol. 17, no 2, pp. 101–112, jun. 2014, doi: 10.1007/s10729-013-9248-9.
- [17] G. Gong, Y. Chen, H. Gao, D. Su, e J. Chang, “Has the Efficiency of China’s Healthcare System Improved after Healthcare Reform? A Network Data Envelopment Analysis and Tobit Regression Approach”, *Int. J. Environ. Res. Public Health*, vol. 16, no 23, 02 2019, doi: 10.3390/ijerph16234847.
- [18] M. S. de C. Lobo, H. de C. Rodrigues, E. C. G. André, J. A. de Azeredo, e M. P. E. Lins, “Dynamic network data envelopment analysis for university hospitals evaluation”, *Rev. Saúde Pública*, vol. 50, 2016, doi: 10.1590/S1518-8787.2016050006022.

- [19] S.-G. C. Mohd e Z. A. Karim, “Public Spending Efficiency And Political And Economic Factors: Evidence From Selected East Asian Countries”, *Econ. Ann.*, vol. 57, no 193, pp. 7–24, 2012.
- [20] F. A. Sedin, E. B. Mariano, Santana, N. B., D. A. N. Rebelatto, J. R. Rebelatto, “Effects of an adapted physical activity program on the physical condition of elderly women: an analysis of efficiency”, *Brazilian Journal of Physical Therapy*, vol. 16, no 4, pp. 328-336. doi: 10.1590/S1413-35552012005000025
- [21] C. A. Bana e Costa, J. C. B. Soares de Mello, e L. Angulo Meza, “A new approach to the bi-dimensional representation of the DEA efficient frontier with multiple inputs and outputs”, *Eur. J. Oper. Res.*, vol. 255, n° 1, p. 175–186, nov. 2016, doi: 10.1016/j.ejor.2016.05.012.
- [22] Domingos Alves, Rodrigo Gaete, Newton Miyoshi, Bruno Carciofi, Lariza Oliveira, e Lariza Oliveira, “Estimativa de Casos de COVID-19”. <https://ciis.fmrp.usp.br/covid19-subnotificacao/> (acessado maio 12, 2020).
- [23] T. D. de Barros, T. G. Ramos, J. C. C. B. S. de Mello, e L. A. Meza, “Avaliação dos atrasos em transporte aéreo com um modelo DEA”, *Production*, vol. 20, no 4, p. 0–0, dez. 2010, doi: 10.1590/S0103-65132010005000047.
- [24] F. B.A.R. Mariz; M. R. Almeida, D. Aloise. “A review of Dynamic Data Envelopment Analysis: state of the art and applications.” *International Transactions in Operational Research*, vol. 01, pp. 1-37, 2017.
- [25] M. V. D. Assunção; M. M. Viera; M. R. Almeida, L. M. L. S. Torres. “Um Estudo da Eficiência Dinâmica Ambiental dos Campos de Petróleo da Bacia Potiguar/Brasil”. *Interiencia*, vol. 42, p. 18-31, 2017.
- [26] L. M. S. Torres, M. R. de Almeida and J. C. S. de Mello, "A literature review of Dynamic and Network Data Envelopment Analysis models in the energy sector," 2018 Simposio Brasileiro de Sistemas Elétricos (SBSE), Niteroi, 2018, pp. 1-6, doi: 10.1109/SBSE.2018.8395605.
- [27] S. Y. Kanematsu, N. Paranagua; C. A. J. Martinhon, M. R. Almeida. “Ranking using n-efficiency and relative size measures based on DEA.” *Omega*, vol. 90, 2020.



Enzo Barberio Mariano nasceu na cidade de São Carlos, São Paulo. Concluiu a sua graduação, mestrado e doutorado em Engenharia de Produção pela Universidade de São Paulo (USP). Possui também graduação em pedagogia pela Universidade Federal de São Carlos (UFSCar). Atualmente é docente no departamento de engenharia de produção e coordenador dos programas de mestrado e doutorado em engenharia de produção da UNESP de Bauru. Sua principal área de pesquisa é Análise Envolvória de Dados, Sustentabilidade e Desenvolvimento humano. É bolsista de Produtividade em Pesquisa do CNPq.



Bruno G. Torres nasceu na cidade de Niterói, Rio de Janeiro. Concluiu a sua graduação e mestrado em Engenharia de Produção pela Universidade Federal Fluminense (UFF), com conclusão em dezembro de 2014 e julho de 2017, respectivamente. Atualmente é aluno de doutorado em Engenharia de Produção (Pesquisa Operacional) pela mesma instituição e Professor Substituto de Engenharia de Produção no Campus de Petrópolis da Universidade Federal Fluminense. Sua principal área de pesquisa é Análise Envolvória de Dados e Auxílio Multicritério a Decisão.



Mariana Rodrigues de Almeida nasceu na cidade de Natal, Rio Grande do Norte. Concluiu a sua graduação na Universidade Federal do Rio Grande do Norte (UFRN), mestrado e doutorado em Engenharia de Produção pela Universidade de São Paulo (USP), pós-doutorado pela Universidade Federal Fluminense (UFF). Atualmente é professora Associada do departamento de Engenharia de Produção da UFRN. Suas publicações são da área de Análise Envoltória de Dados e Inovação tecnológica



Diogo Ferraz nasceu em Rio das Pedras, São Paulo. Possui graduação em Ciências Econômicas, doutorado em Engenharia de Produção pela Universidade de São Paulo (Brasil) e é *Ph.D. candidate* em Economia da Inovação na Universidade de Hohenheim (Alemanha). A área de pesquisa relaciona Desenvolvimento Humano e Complexidade Econômica. É professor da Universidade Federal Rural da Amazônia (UFRA).



Daisy A. do N. Rebelatto nasceu em Monte Aprazível, São Paulo. Possui graduação em Engenharia Civil pela Universidade Federal de São Carlos, mestrado em Engenharia de Produção pela Universidade de São Paulo, doutorado em Engenharia Mecânica pela Universidade de São Paulo, pós-doutorado pela Universidad Complutense de Madrid e pela Universidad de Salamanca, livre-docência pela Universidade de São Paulo. Tem publicações nas áreas de Análise Envoltória de Dados e Projetos de Investimento, com ênfase em políticas públicas, desenvolvimento sustentável e inovação. Bolsista de Produtividade em Pesquisa do CNPq.



João Carlos Soares de Mello nasceu em Lisboa, Portugal. Fez graduação em Engenharia Mecânica e mestrado em Matemática na Universidade Federal Fluminense, Brasil. Fez doutorado em Engenharia de Produção, área de Pesquisa Operacional, na Universidade Federal do Rio de Janeiro, Brasil. Foi chefe do Departamento de Matemática Aplicada e de Engenharia de Produção na Universidade Federal Fluminense. Tem artigos publicados nas áreas de Análise Envoltória de Dados e Auxílio Multicritério à Decisão e é bolsista de Produtividade em Pesquisa do CNPq.